

THÈSE DE MAÎTRISE PRÉSENTÉ À:

*L'UNIVERSITÉ DU QUÉBEC
À TROIS-RIVIÈRES*

*COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN GÉNIE INDUSTRIEL*

PAR:

MARCO PATRY ing.

**"MODELISATION DE LA DÉFIBRATION
SECONDAIRE DE LA PÂTE CELLULOSE
À L'AIDE D'UN RÉSEAU DE NEURONES"**

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire ou de cette thèse a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire ou de sa thèse.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire ou cette thèse. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire ou de cette thèse requiert son autorisation.

Remerciements

Dans un premier temps, un merci tout spécial à SCA et à mon superviseur, Benoît Coulombe, qui m'a permis de mener à bien cette expérience et qui m'a permis de m'enrichir de nouvelles connaissances.

Un gros merci aussi à Luc Laperrière, mon responsable de recherche qui m'a guidé de façon très éclairée tout au long de ma recherche et qui a dû passer plusieurs heures à résoudre des problèmes informatiques inattendus reliés à Cadsim.

Enfin, un merci à tous ceux, qui de près ou de loin, ont collaboré avec moi tout au long de cette recherche que ce soit au niveau du laboratoire avec Jean, Thérèse, France et tous les autres ou au niveau technique avec Jack, David et Yves, merci encore une fois.

Finalement, un merci inestimable à ma conjointe, Sandra, qui a su conjuguer avec mes nombreuses absences les soirs de semaine ainsi que pendant des fins de semaines entières. Une partie de ce succès te revient indirectement. Sans toi ça n'aurait jamais été possible.

Marco

RÉSUMÉ

L'objectif visé par cette recherche sera de comprendre le procédé de formation d'un matelas contenu à l'intérieur d'un produit d'incontinence pour adulte. L'outil utilisé, pour bien comprendre les différentes interactions « machine » pour produire ce matelas, sera l'outil de programmation des réseaux de neurones. L'atteinte de l'objectif sera permise à l'aide du logiciel des réseaux de neurones "Cadsim" de la compagnie "Aurel Systems inc.". La méthodologie suivie pour conduire l'expérience consistera d'abord en une séance de brainstorming avec les différents experts locaux pour déterminer les variables les plus susceptibles d'influencer les caractéristiques qualitatives du matelas. Ensuite, en collaboration avec un plan expérimental choisi, des expériences « machine » seront effectuées et des valeurs tests seront recueillies pour fin d'analyses avec le réseau de neurones. Une étude de Pareto sera menée parallèlement pour valider les résultats trouvés à l'aide du logiciel de réseau de neurones. Enfin, l'établissement d'un tableau final incluant des résultats ayant sur ses axes les variables dépendantes versus les variables indépendantes, permettra de voir d'une façon plus globale comment se déroulaient les différents comportements à l'intérieur de la machine de production. Les conclusions de cette étude auront montré que le plan expérimental choisi ne fut pas optimal à cause des non-linéarités sur certaines variables indépendantes. Ce manquement a fait en sorte qu'il aura été impossible de quantifier de façon exacte les interactions « machine ». Malgré tout, un bon nombre de variables dépendantes et indépendantes auront été bien comprises par rapport à leurs tendances et interactions. Malgré tout, il sera possible d'affirmer que l'objectif principal de cette recherche aura été atteint.

Mots clés: neurones, hygiène, plan, Pareto, factoriel, Cadsim, interactions, variables.

TABLE DES MATIÈRES

Protection des informations confidentielles	i
Remerciements	ii
Résumé	iii
Table des matières	iv
Chapitre I - Introduction	1
Organisation du chapitre	2
1.1 Origine du problème étudié	2
1.2 Présentation de l'environnement de recherche	3
1.3 Objectifs de la recherche	6
1.4 Introduction aux plans d'expériences	7
1.4.1 Exemple	8
1.5 Introduction aux réseaux neuroniques	9
1.5.1 Description d'un réseau	9
1.5.1.1 Algorithme de propagation inverse de l'erreur	11
1.5.1.2 Apprentissage et entraînement	13
1.5.1.3 Généralisation et performance de l'algorithme	14
1.6 Limites et délimitations de la recherche	15
Chapitre II - Recherche littéraire	17
Organisation du chapitre	17
2.1 Pertinence et originalité	17
2.2 Vue d'ensemble des articles	18
2.2.1 Articles sur la base des RDN.	20
2.2.2 Articles utilisés au déroulement de la recherche	22
2.3 Les plans expérimentaux	25
2.4 Les avenues inexplorées	25
2.4.1 Les algorithmes génétiques	26
2.4.2 Les algorithmes de Quasi-Newton et Simplex	28
2.4.2.1 Quasi-Newton	29
2.4.2.2 Simplex de base	29
2.4.2.3 Simplex modifié	31
2.5 Positionnement face à la recherche littéraire	32
Chapitre III - Description de la méthodologie utilisée	34
Organisation du chapitre	34
3.1 Organisation de la recherche	34
3.2 Détermination des variables dépendantes et indépendantes	35

3.3 Détermination du plan expérimental à prendre	36
3.4 Conduite des expériences et enregistrement des données	39
3.5 Méthodologie sur l'analyse de variabilité et sensibilité par Pareto	40
3.6 Méthodologie d'analyse des résultats par RDN	43
3.6.1 Architecture et entraînement des RDN	43
3.6.2 Méthodologie d'entraînement utilisée lors de la recherche	44
3.6.3 Analyse de sensibilité par RDN	46
3.7 Création du tableau final	48
Chapitre IV - Analyse des résultats (Variables dépendantes)	50
4.1 Retour sur les résultats d'expériences "machine"	50
4.2 Résultats sur les entraînements	52
4.3 Résultats sur les analyses du RDN	53
4.3.1 Tenue matelas (TM)	54
4.3.1.1 Interprétation des résultats	55
4.3.2 Temps d'acquisition (TA)	56
4.3.2.1 Interprétation des résultats	58
4.3.3 Rétention (RET)	59
4.3.3.1 Interprétation des résultats	60
4.3.4 Absorption totale (AT)	62
4.3.4.1 Interprétation des résultats	64
4.3.5 Absorption 10 pouces (ABS10)	66
4.3.5.1 Interprétation des résultats	67
4.3.6 Défibration (%ACC)	68
4.3.6.1 Interprétation des résultats	69
Chapitre V - Conclusion	72
5.1. Conclusion de l'analyse des variables dépendantes	72
5.2. Conclusion de l'analyse des variables indépendantes	73
5.3. Valeurs de mise en route optimale	75
5.4. Conclusion générale	77
Liste des références	79
Bibliographie	80
Annexe 1: Feuille de résultats d'essais Palmer	83
Annexe 2: Précision des entraînements (Borland)	88
Annexe 3: Précision des validations (Cadsim)	89
Annexe 4: Calculs des effets lors de l'analyse par Pareto	90
Annexe 5: Graphes des effets par Pareto	91
Annexe 6: Graphes de Pareto	93
Annexe 7: Tableaux des effets calculés par RDN	95

LISTE DES FIGURES

FIGURES DU CHAPITRE 1:

1.1: DÉFIBRATION DE LA PÂTE. _____	4
1.2 : BROEUR À MARTEAUX. _____	5
1.3 : ROULEAU ÉGALISATEUR ET FORMATION. _____	5
1.4 : FORMATION DU MATELAS. _____	6
1.5 : DIAGRAMME D'UN RÉSEAU DE NEURONES SIMPLE. _____	7
1.6 : UN NEURONE SIMPLE. _____	10
1.7 : UN NEURONE ARTIFICIEL DE BASE. _____	10
1.8 : CONFIGURATION GRAPHIQUE DE L'ALGORITHME À PROPAGATION INVERSE. _____	11
1.9 : EXEMPLE DE FONCTION DE TRANSFERT. _____	12
1.10 : LA SIGMOÏDE. _____	13

FIGURES DU CHAPITRE 2:

2.1: PSEUDO-CODE DE L'ALGORITHME GÉNÉTIQUE STANDARD. _____	28
2.2: REPRÉSENTATION D'UN SIMPLEX STANDARD. _____	31
2.3: SÉQUENCE D'OPTIMISATION TYPIQUE D'UN SIMPLEX MODIFIÉ. _____	32

FIGURES DU CHAPITRE 3:

3.1: GRAPHE DES EFFETS SUR LE TEMPS D'ACQUISITION. _____	42
3.2: GRAPHE DE PARETO POUR LE TEMPS D'ACQUISITION. _____	43

FIGURES DU CHAPITRE 4:

4.1: REPRÉSENTATION PHYSIQUE DES CALCULATEURS DU RDN. _____	51
4.2: DISTRIBUTION DES VALEURS DE TA. _____	53
4.3: INTERACTION ENTRE "DISCAL" ET "DISBROSS" _____	58

LISTE DES TABLEAUX

TABLEAUX DU CHAPITRE 1:

1.1: MATRICE DES ESSAIS. _____	9
--------------------------------	---

TABLEAUX DU CHAPITRE 2:

2.1: SÉLECTION DE RÉSEAUX. _____	19
2.2: LISTE DES ARTICLES. _____	20

TABLEAUX DU CHAPITRE 3:

3.1: VARIABLES SUGGÉRÉES POUR L'ÉTUDE. _____	35
3.2: CARACTÉRISTIQUES DU FACTORIEL FRACTIONNÉ _____	37
3.3: MATRICE CODÉE DES ESSAIS. _____	38
3.4: DESCRIPTION DES VARIABLES INDÉPENDANTES. _____	38
3.5: RÉSUMÉ DES RÉSULTATS OBTENUS. _____	40
3.6: DONNÉES DE DÉPART POUR PARETO. _____	41
3.7: CALCULS DES EFFETS. _____	41
3.8: ENTRAÎNEMENT DES DONNÉES. _____	46
3.9: ANALYSE DES EFFETS PAR RDN SUR LE TEMPS D'ACQUISITION. _____	47
3.10: SOMMAIRE DES RÉSULTATS OBTENUS. _____	48

TABLEAUX DU CHAPITRE 4:

4.1: ERREURS RELIÉES À L'ÉCART TYPE. _____	51
4.2 CALCULS DES EFFETS PAR RDN POUR TM. _____	54
4.3: COMPARATIF DES RÉSULTATS OBTENUS SUR TM. _____	56
4.4: CALCULS DES EFFETS PAR RDN SUR TA. _____	57
4.5: COMPARATIF DES RÉSULTATS OBTENUS SUR TA. _____	58
4.6: CALCULS DES EFFETS PAR RDN SUR RET. _____	59
4.7: COMPARATIF DES RÉSULTATS OBTENUS SUR RET. _____	61
4.8: CALCULS DES EFFETS PAR RDN POUR AT, ESSAI 19 INCLUS. _____	63
4.9: CALCULS DES EFFETS PAR RDN POUR AT, ESSAI 19 NON INCLUS. _____	64
4.10: COMPARATIF DES RÉSULTATS OBTENUS SUR AT. _____	65
4.11: CALCULS DES EFFETS PAR RDN POUR ABS10. _____	67
4.12: COMPARATIF DES RÉSULTATS OBTENUS SUR ABS10. _____	68
4.13 CALCULS DES EFFETS PAR RDN POUR % ACC. _____	69
4.14: COMPARATIFS DES RÉSULTATS OBTENUS SUR % ACC. _____	70

TABLEAUX DU CHAPITRE 5:

5.1: RÉSULTATS GLOBAUX DES EFFETS. _____	73
5.2: VALEURS DE DÉPART POUR L'ANALYSE. _____	76
5.3: VALEURS OBTENUES AVEC LES VALEURS DE DÉPARTS. _____	76
5.4: VALEURS FINALES POUR L'ANALYSE. _____	76
5.5: VALEURS OBTENUES AVEC LES NOUVELLES VALEURS. _____	77

LISTE DES ÉQUATIONS

ÉQUATION DU CHAPITRE 1:

1.1:

$$\dot{W} = W - \eta \nabla_{\epsilon}(w)$$

1.2:

$$N > W/\epsilon$$

ÉQUATION DU CHAPITRE 2:

2.1:

$$f(x) = 1 / (1 + e^{-\alpha x / \beta})$$

2.2:

$$V|_{xp} = \frac{\sum [(|I|_{pj} / \sum |I|_{pi,k}) |O|_j]}{\sum [(|I|_{pi,j} / \sum |I|_{pi,j,k}) |Q|_j]}$$

2.3:

$$R^2 = 1 - (SSE/TSS)$$

2.4:

$$\max R^2 = 1 - (S^2 / S_0^2)$$

2.5:

$$\nabla^2 r(\vec{x}) = \begin{pmatrix} \frac{\partial^2 r(\vec{x})}{\partial x_1^2} & \dots & \frac{\partial^2 r(\vec{x})}{\partial x_1 \partial x_n} \\ \vdots & & \vdots \\ \frac{\partial^2 r(\vec{x})}{\partial x_1 \partial x_n} & \dots & \frac{\partial^2 r(\vec{x})}{\partial x_n^2} \end{pmatrix}.$$

CHAPITRE I

INTRODUCTION

Pour qu'une recherche telle que la nôtre soit menée rondement avec un minimum d'embûches, il faut que cette dernière soit bien planifiée et bien préparée afin d'obtenir l'atteinte optimale des objectifs. C'est pourquoi, par ce travail, il sera tenté de démontrer du mieux possible, l'étendue des démarches prises pour mener à bien cette recherche. En conséquence, il sera possible de comparer les résultats de certaines expériences, obtenus par calculs des réseaux de neurones par rapport à ce qui s'est passé en réalité sur machine. Cette comparaison faisant foi de l'intégrité de la recherche, il sera alors possible de savoir si les objectifs ont été atteints ou non.

D'abord pour bien comprendre pourquoi cette recherche a été effectuée et d'où elle vient, il sera tenté, dans un premier temps, de décrire brièvement dans quel environnement se situe le problème étudié et quels en sont les buts et objectifs. De même, des introductions de base sur les réseaux de neurones et sur les plans d'expériences seront offertes pour les lecteurs non initiés.

Dans un second temps, à l'aide d'une recherche littéraire, il sera tenté de délivrer les tous derniers développements sur le domaine particulier de cette recherche. Bien que l'application des réseaux de neurones ne soit pas très développée dans l'industrie de la transformation secondaire des pâtes et papiers, il sera possible de voir, que dans beaucoup d'autres domaines, les réseaux de neurones sont déjà bien installés.

Dans un troisième temps, une description de la méthodologie employée pour mener à bien la recherche sera offerte. En plus d'expliquer tout le cheminement parcouru par le chercheur lors de la recherche, ce chapitre verra à donner des analyses et des explications plus poussées à propos des plans d'expériences et des réseaux de neurones utilisés lors de la recherche.

Enfin, dans un dernier temps, il sera vu plus en détail l'analyse des résultats ayant trait aux expériences sur la modélisation par réseaux de neurones sur la défibration secondaire de la pâte cellulosique.

ORGANISATION DU CHAPITRE

Le contenu de cette section regroupe des informations quant à l'introduction et la présentation de la recherche. Cette section sert, en fait, à bien établir les bases de la recherche en cours et à préparer la table pour certains chapitres subséquents.

Dans les différentes sous-sections rencontrées, il sera possible de prendre connaissance de l'origine du problème, quelles ont été les premières approches, comment ce problème se définit et quels sont les buts et objectifs poursuivis. Une présentation de l'environnement de recherche sera aussi montrée pour bien situer le lecteur avant d'entreprendre cette lecture.

Pour bien initier le lecteur aux méthodes d'analyses employées sur la cueillette des données lors de la recherche, une introduction aux plans d'expériences sera offerte. Cette introduction donnera les renseignements essentiels au lecteur pour qu'il puisse bien faire le lien entre les plans d'expériences et les réseaux de neurones.

D'un point de vue plus orienté vers le processus de recherche des résultats, une introduction aux réseaux de neurones sera aussi offerte. Une description générale du fonctionnement du réseau utilisé pour cette recherche sera faite. Le but de cette description sera de donner au lecteur une meilleure compréhension de ce qui justifie l'utilisation de cette technologie pour la recherche.

Enfin il sera possible de prendre connaissance de l'étendue de la recherche. Il sera possible, dans ce sens, de connaître les limitations de la recherche et où sont situées les délimitations de cette dernière.

1.1 ORIGINE DU PROBLÈME ÉTUDIÉ

Avant de situer le problème, il serait probablement bon d'expliquer dans quel contexte se situe la recherche de laquelle nous aurons à traiter. Pour bien situer le lecteur, nous pouvons d'abord dire que le type de recherche se situe dans le domaine des produits hygiéniques, plus particulièrement dans le domaine de l'incontinence pour adulte. La compagnie pour laquelle cette recherche est effectuée est la multinationale suédoise SCA Mölnlycke, mieux connue aujourd'hui sous le nom de SCA Produits d'Hygiène, division Drummondville.

L'origine de cette demande de recherche se situe autour du mois de juin 1998, sur la ligne de production appelée Palmer, en l'honneur de sa ville d'origine aux États-Unis. Durant cette période la compagnie effectuait des tests sur un nouveau produit ayant une forme anatomique, du jamais vu depuis longtemps sur cette ligne de production. Considérant que ce nouveau produit demandait plus de poids au niveau du matelas et que la ligne de production devait toujours rester à la même vitesse, il y avait alors un problème d'approvisionnement en pâte cellulose. Les deux rouleaux de pâte devaient maintenant fournir à plus haute vitesse, ce qui occasionnait des problèmes de bourrage au poste de défibrage. La limite que pouvait fournir la machine au point de vue

approvisionnement en pâte était alors atteinte. Pendant un des essais « machine », un opérateur suggéra d'ajouter un troisième rouleau de pâte; l'idée fut essayée et immédiatement les objectifs de poids sur le matelas ont été atteints, tout en conservant une vitesse raisonnable d'entrée des pâtes.

À la suite des résultats en laboratoire, la surprise fut de découvrir que certains tests de performance comme, par exemple l'absorption totale, étaient de façon constante, légèrement supérieurs aux autres tests faits auparavant lorsque le système d'approvisionnement fonctionnait à deux pâtes. C'est à partir de ce moment que la réflexion fut faite à savoir " pourquoi trois pâtes au lieu de deux? ". C'est aussi à ce moment que nous avons réalisé l'incompréhension des interactions de la machine en fonction des performances de nos produits. Après avoir fait une brève enquête, même le fabricant ne pouvait expliquer pourquoi les trois pâtes donnaient de meilleures performances que les deux pâtes. Par contre, ce dernier pouvait très bien expliquer son fonctionnement mécanique.

Ainsi est venu le goût de savoir comment fonctionnent les interactions de la machine versus les performances du produit. Lors d'une réunion, une suggestion fut faite à mon supérieur par rapport à un outil pouvant résoudre ce type de problème. Selon mes connaissances, seul un réseau de neurones pouvait répondre aussi adéquatement aux diverses questions qui se posaient. Après avoir pris différentes informations et rencontré mon superviseur de recherche, la compagnie et moi avons décidé de pousser les recherches dans ce sens. Nous étions maintenant prêts à commencer la cueillette des données.

1.2 PRÉSENTATION DE L'ENVIRONNEMENT DE RECHERCHE

Avant de donner en détail l'explication du processus de recherche qui sera appliqué, il sera possible de voir une brève présentation des principales sections « machine » qui seront étudiées sur la ligne de production Palmer.

Il faut tout d'abord se rappeler que le travail se fait dans un environnement de transformation de matière première. Le produit fini en bout de ligne est une culotte d'incontinence pour adulte.

Sur la Figure 1.1, il est possible de voir l'ensemble d'alimentation de pâte et broyeur à marteaux. Cet ensemble sert à transférer les pâtes (1) dans le broyeur à marteaux (2) dans un but de défibrage et ensuite d'acheminer les pâtes broyées (ouate) vers le tambour de formation (3).

Sur la Figure 1.2, il est possible de voir le fonctionnement du broyeur à marteaux. Les rouleaux d'entraînement alimentent le broyeur en pâte et grâce à l'action du rotor du broyeur, ce dernier tourne et les marteaux défibrent les pâtes pour effectuer la transformation en ouate. De façon analogue à une paire de ciseau, le déchiquetage de la pâte se fait à l'aide de deux pièces, la partie mobile étant le broyeur à marteaux et la partie fixe le "breaker bar". La distance entre la partie mobile et la partie fixe

influencera les caractéristiques du broyage du matelas. Ce phénomène sera expliqué plus loin dans une autre section.

Une fois la pâte transformée en ouate, cette dernière vient se coller via une aspiration sur le tambour de formation. Ce tambour rotatif possède plusieurs pochettes moulées et vient faire passer l'ouate vis-à-vis un rouleau égalisateur. Après ce rouleau égalisateur nous serons prêts à venir déposer le matelas sur un convoyeur pour qu'il puisse par la suite subir une série de transformations le menant vers sa version finale. Ceci sera démontré plus bas par les Figures 1.3 et 1.4.




FIGURE 1.1: DÉFIBRATION DE LA PÂTE.

1. Supports des rouleaux de pâte.
2. Broyeur à marteaux servant à transformer la pâte en ouate.
3. Tambour de formation.




FIGURE 1.2 : BROYEUR À MARTEAUX.

1. Aspiration des poussières. Les poussières sont dirigées vers un dépoussiéreur de type Osprey.
2. Entrée du super absorbant.
3. Rouleaux d'entraînements des pâtes.




FIGURE 1.3 : ROULEAU EGALISATEUR ET FORMATION.

1. Rouleau égalisateur qui enlève le surplus d'ouate et redistribue de façon égale l'ouate le long de la pochette.
2. Pochette de formation. Selon les modèles produits, il sera possible d'avoir 5, 6, 7 ou 8 pochettes.




FIGURE 1.4 : FORMATION DU MATELAS.

1.3 OBJECTIFS DE LA RECHERCHE

Avant de commencer cette recherche, il serait bon de préciser de quel type de recherche il est question. Le but premier de cette recherche n'est pas d'essayer de trouver de nouveaux outils de calculs pour les réseaux de neurones ou de nouveaux algorithmes de convergences. En fait, la cible de cette recherche est de prendre des outils existants et éprouvés dans le domaine des réseaux de neurones et de les appliquer dans un domaine précis où encore personne n'est allé. Ce domaine est celui de la défibrillation secondaire de la pâte cellulosique. Bien que des études aient porté sur des domaines connexes comme le blanchiment des pâtes ou les brisures de tissu, celui-ci aura la particularité de s'appliquer sur un produit en dernière transformation donc qui sera directement vendu au client à sa sortie de la ligne de production. La présente recherche pourrait être formulée de la façon suivante. À l'aide d'un outil mathématique de programmation tel le réseau de neurones, (Figure 1.5 de la page 7) il sera tenté, à l'aide de certaines variables indépendantes "input" et dépendantes "output" de la machine de production "Palmer", de reproduire le plus fidèlement possible les tendances et interactions des variables de production.

La justification de cette étude sera complète quand il sera possible de comprendre les interactions complètes des différentes variables indépendantes vis-à-vis la formation du matelas. Il sera tenté de parvenir à une compréhension du système qui fera en sorte qu'une optimisation des différentes variables en fonction du ratio coûts/qualité sera atteint.




FIGURE 1.5 : DIAGRAMME D'UN RÉSEAU DE NEURONES SIMPLE. [1]

L'objectif ultime est donc de comprendre le procédé de formation du matelas de la machine Palmer via les différentes courbes multidimensionnelles générées par le réseau de neurones. L'atteinte de cet objectif sera permise à l'aide du logiciel de réseau de neurones "Cadsim" fourni par la compagnie Aurel Systems inc. Grâce à ce logiciel, il est possible de traiter, à partir d'une série de variables d'entrées ou paramètres d'ajustements, la prédiction exacte d'une série de variables de sortie ou paramètres de qualité.

1.4 INTRODUCTION AUX PLANS D'EXPÉRIENCES

Pour fournir le réseau de neurones en données pour fins de calculs, il faut faire une série d'expériences sur machine. Cette cueillette de données ne peut se faire au hasard en prenant des valeurs d'ajustements « machine » ici et là, c'est à ce moment qu'intervient le concept du plan d'expérience ou plan expérimental.

Il est légitime, à ce moment, de se demander pourquoi prendre un design de plan expérimental pour mener une expérience [1,2]. Voici quelques raisons:

- Optimiser le nombre d'essais à effectuer en fonction de la précision à obtenir.
- Éviter d'effectuer des expériences dans une même région du domaine à l'étude (orthogonalité).
- Possibilité d'étudier des variables qualitatives et quantitatives avec un même type de plan lors d'une même étude.

Pour bien comprendre l'impact du plan expérimental, il est possible de voir qu'il existe deux types de classes pouvant les définir [2].

- D'abord, la classe qui porte à trouver une valeur moyenne la plus juste possible.

- Enfin, celle qui porte à trouver la variabilité dans un procédé.

La classe qui nous intéresse est bien certainement celle qui traite de la variabilité dans un procédé. Originellement, les designs de plans expérimentaux étaient surtout utilisés avec les régressions simples ou multiples. Aujourd'hui encore, les analyses de variances aussi appelé "ANOVA" et les régressions multiples sont beaucoup utilisées.

Le choix du plan expérimental se fait en fonction de quelques variables. Ces variables peuvent être très différentes d'une recherche à l'autre [2]. Voici donc quelques variables à considérer lors du choix d'un plan expérimental:

- Le nombre de variables dépendantes et indépendantes à considérer.
- Le nombre de niveaux des variables à étudier.
- Le nombre d'expériences permises à effectuer sur machine.
- Le niveau de confiance à atteindre.

1.4.1 EXEMPLE

Voici un exemple simple qui montre le lien entre le plan expérimental et la recherche à effectuer.

Prenons le cas où l'étude serait faite sur deux variables indépendantes en fonction de trois variables dépendantes ou variables de sortie. Avec seulement deux variables indépendantes et seulement deux niveaux (bas et haut) sur chaque variable, un maximum de 2^2 possibilités au point de vue des combinaisons existantes pour connaître au maximum le domaine d'étude réalisable seraient considérées. Le chiffre « deux » représente le nombre de niveaux sur chaque variable tandis que l'exposant « deux » représente le nombre de variables à l'étude, nous aurons en tout quatre possibilités d'expériences. Vu le nombre peu élevé d'expériences à effectuer pour connaître le domaine réalisable, il est possible de considérer comme choix de plan expérimental, le « full factoriel ». Ce plan est celui où toutes les possibilités d'ajustements sont considérées. Il est alors peu important de s'en faire pour ce qui est de l'orthogonalité des points d'expériences à aller chercher puisque que tous les points sont considérés.

Donnons comme nom les lettres A et B à nos deux variables indépendantes à étudier. Le Tableau 1.1, montré à la page suivante, illustre la série d'expériences à effectuer pour aller chercher les données tests qui entraîneront le réseau de neurones un peu plus tard.

Essai	A	B
1	+	+
2	+	-
3	-	+
4	-	-

TABLEAU 1.1: MATRICE DES ESSAIS.

En faisant les essais un, deux, trois et quatre, selon les niveaux hauts (+) et bas (-) concernés, les quatre séries de données nécessaires pour entraîner notre réseau de neurones sont recueillies. Le lien entre le plan expérimental et la recherche est maintenant fait.

1.5 INTRODUCTION AUX RÉSEAUX NEURONIQUES

Avant d'élaborer pleinement sur les réseaux de neurones et les derniers développements, il serait probablement utile au lecteur non initié à cette technologie, de comprendre un peu plus ce qu'est un réseau de neurones. À cet effet, voyons d'abord une brève théorie à propos de cette technologie qu'est le réseau de neurones.

1.5.1 DESCRIPTION D'UN RÉSEAU

Les réseaux de neurones sont des modèles de programmation basés sur la structure du cerveau humain. Le cerveau a comme caractéristique particulière d'apprendre à partir des expériences passées. C'est ce que nous essaierons de simuler avec les réseaux de neurones.

L'élément fondamental du réseau de neurones est le neurone. À la base, un neurone biologique reçoit des signaux d'entrées à partir d'autres sources extérieures par ses dendrites. Il combine ces différentes sources et génère une opération non linéaire sur le résultat, grâce à sa fonction de sommation au nœud. Il envoie ensuite ses signaux de sortie via l'axone vers les synapses. Chaque synapse s'occupe d'établir des liens avec les autres neurones. Ce processus avec ses quatre parties principales est montré schématiquement à la Figure 1.6.




FIGURE 1.6 : UN NEURONE SIMPLE. [1]

D'un côté plus pratique, il est possible de définir un réseau de neurones comme un graphe dirigé étant constitué de nœuds ayant des interconnexions synaptiques et des liens d'activation. La Figure 1.7, montre de façon plus claire la représentation d'un neurone artificiel. A partir de cette image, il est maintenant possible de se faire une idée plus claire de ce que peut représenter un réseau.




FIGURE 1.7 : UN NEURONE ARTIFICIEL DE BASE. [1]

À partir de la brève description d'un neurone artificiel les quatre propriétés principales de ce type de neurone sont les suivantes [3]:

- Chaque neurone est représenté par un assortiment de lien synaptique, un seuil d'application externe ou biais et un lien d'activation non linéaire représentant cet assortiment. Le seuil d'activation ou biais est représenté par un signal d'entrée fixé à la valeur -1 et permettra à l'algorithme de trouver un hyperplan séparateur via une fonction de transfert sans restriction dans l'espace « p » tout en calculant dans l'espace $p+1$. En mettant un biais $\neq 0$, il est possible d'augmenter sensiblement le pouvoir de séparation de la cellule. Cette valeur permettra donc de faire la distinction entre les valeurs -1 et 1 sans passer par l'origine.
- Les liens synaptiques d'un neurone sont le poids de leurs signaux d'entrées respectifs.
- La somme des poids des signaux d'entrées définit le niveau d'activité interne du neurone en question.
- Le lien d'activation ressort le niveau d'activité interne du neurone qui produit alors un signal de sortie qui représentera la variation d'état du neurone.

Enfin, l'architecture du réseau est un élément déterminant sur la performance de ce dernier. La façon dont les neurones d'un réseau sont structurés est intimement liée avec l'algorithme d'apprentissage utilisé pour entraîner le réseau. En allant voir plus loin

au Tableau 1.2, il est possible de voir qu'il existe plusieurs types d'algorithmes d'apprentissage. Celui qui est le plus intéressant considérant le type de recherche à faire est l'algorithme de propagation inverse de l'erreur.

1.5.1.1 ALGORITHME DE PROPAGATION INVERSE DE L'ERREUR

Ce type d'algorithme est aussi connu sous le nom de « perceptron » à niveaux multiples mais fonctionne sous l'algorithme de propagation inverse. L'algorithme fonctionne en deux temps bien précis. D'abord, sur une passe avant « forward pass » ensuite l'algorithme revient en arrière pour faire les corrections « backward pass ». Ces deux types de passes sont définies comme suit [3] :

- Passe avant « forward pass » : un modèle d'activité ou vecteur d'entrée est appliqué aux nœuds sensitifs du réseau et son effet se propage au travers du réseau, niveau par niveau.
- Passe arrière « backward pass » : les poids synaptiques sont réajustés en concordance avec la règle de correction d'erreur.

La Figure 1.8 donne un aperçu de la configuration graphique de l'algorithme de propagation inverse. Pour cette configuration graphique particulière, le réseau est dit « fully connected » ou pleine connexion. Cette configuration n'est qu'une des multiples configurations que peut prendre un réseau. Après optimisation, le réseau peut perdre des liens entre chaque niveau. Chaque type de problèmes rencontrés a donc sa propre configuration de réseau.




FIGURE 1.8 : CONFIGURATION GRAPHIQUE DE L'ALGORITHME À PROPAGATION INVERSE. [1]

Voici maintenant les trois caractéristiques du « perceptron multi-niveaux » [3] :

1. Le modèle de chaque neurone dans le réseau inclut une fonction de transfert. Il existe différentes fonctions de transfert, la Figure 1.9, de la page suivante, montre les trois principales. Dans notre cas, celui du « perceptron multi-niveaux », une non-

linéarité par rapport à la réponse finale est définie. Cette non-linéarité satisfaisant nos besoins est donc définie par la sigmoïde.

2. La Figure 1.10 montre plus en détail comment se comporte ce type de fonction. Cette non-linéarité est importante puisque sans elle la relation « variable d'entrée – variable de sortie » du réseau nous réduirait à un perceptron de niveau simple.
3. Le réseau contient un ou plusieurs niveaux intermédiaires qui ne font pas partie du réseau en tant que variables d'entrée ou de sortie. Ces neurones intermédiaires permettent au réseau d'apprendre des tâches complexes par l'extraction progressive des variables qui, plus tard, en diront long sur les caractéristiques des modèles de variables d'entrées.
4. Le réseau peut montrer un haut degré de connectivité déterminé par les synapses du réseau. Un changement dans la connectivité du réseau requerra un changement dans la population des connections synaptiques ou dans leurs poids.




FIGURE 1.9 : EXEMPLE DE FONCTION DE TRANSFERT. [1]

Tel que vu plus haut, le nombre de niveaux intermédiaires aura un impact immédiat sur l'habileté de généraliser un phénomène et la vitesse de convergence. Il n'existe malheureusement pas de règle qui définit le nombre de niveaux intermédiaires à inclure pour les différentes situations rencontrées. Le mode d'essais – erreurs est encore la façon de faire pour déterminer ce nombre de niveaux intermédiaires. Par contre les niveaux intermédiaires possèdent deux rôles bien connus [3] :

1. La programmation de la fonction « signal » apparaissant à la sortie d'un neurone, laquelle est définie comme une fonction non-linéaire continue du signal de sortie et du poids synaptique, est associée avec ce même neurone.
2. La programmation d'un estimé instantané du vecteur gradient, c'est-à-dire le gradient d'erreur surface reliée aux poids connectés à l'entrée d'un neurone, est nécessaire pour réaliser la propagation inverse du réseau.

1.5.1.2 APPRENTISSAGE ET ENTRAÎNEMENT

Maintenant que les principales caractéristiques du « perceptron multi-niveaux » sont connues, il serait intéressant de connaître le fonctionnement d'apprentissage de ce type de réseau de neurones.




FIGURE 1.10 : LA SIGMOÏDE. [1]

Par définition, l'apprentissage est un procédé par lequel des paramètres libres d'un réseau de neurones sont adaptés au travers d'un processus continu de stimulation par l'environnement auquel le réseau fait partie. Le type d'apprentissage est déterminé par la manière ou la façon dans lesquels les changements sur les paramètres se font. La théorie sur l'apprentissage dit qu'il existe toujours un manque à la pleine compréhension de l'apprentissage qui est, en fait, la structure mathématique décrivant ce processus. Le problème d'apprentissage est de sélectionner depuis une série de variables entrée – sortie, cette fonction particulière $F(x,w)$ qui « approximerait » la réponse désirée du vecteur « d » fourni par un professeur de façon optimum, le terme optimum étant défini au sens statistique.

Dans notre cas du réseau à propagation inverse, l'apprentissage se fait via l'utilisation du calcul d'erreurs par les moindres carrés et du gradient de descente. Dans le jargon de la technologie des réseaux de neurones, on appelle cette règle, la règle du gradient de descente. Utilisant un gradient de poids $\nabla_{\epsilon}(w)$, celui-ci permettra de mettre à jour la valeur courante de « w » par de très petit taux utilisant la forme suivante [3] :

$$W' = W - \eta \nabla_{\epsilon}(w) \quad \text{Éq. 1.1}$$

où : ∇_{ϵ} = différentiel d'erreur

η = taux d'apprentissage

η trop petit = temps de convergence trop grand.

η trop grand = convergence plus rapide mais possibilité de divergence.

De là, il est possible de considérer une variable pour accélérer la convergence sans toutefois trop diverger. Cette variable est connue sous le nom de « momentum ». Ce facteur permettra un apprentissage plus rapide tout en ajustant la variable du taux d'apprentissage η de façon variable. En plus, cette variable diminue les chances de rester pris dans un minimum local.

Maintenant que la méthode d'apprentissage de ce type de réseau de neurones est mieux connue, il est alors possible de passer au mode d'entraînement. Il faudra faire attention ici de ne pas mélanger apprentissage et entraînement. L'entraînement d'un réseau peut se faire de deux façons ; en entraînement supervisé ou en entraînement non supervisé.

L'entraînement supervisé est le type d'entraînement dont il sera question lors de notre recherche. Ce type d'entraînement nécessite des séries de variables pour l'entraînement et des séries de variables pour les tests. Généralement les séries d'entraînements sont générées soit par un logiciel ou par des données recueillies sur le procédé même. Dans notre cas, nous pouvons nous permettre de faire certains essais « machine », il est alors plus avantageux d'aller chercher les variables d'entraînements à cet endroit. Une fois les variables d'entraînement prélevées, il faut soumettre ces dernières au réseau de neurones plusieurs fois de suite pour lui permettre de raffiner les valeurs de connections sur les différents poids. Quand le processus d'entraînement est complet, une série de variables tests est soumise au réseau pour voir si ce dernier généralise bien. Si ce n'est pas le cas, une série de correctifs déjà connus pourront être apportés.

D'un autre côté, l'entraînement non supervisé est plus complexe. Avec ce type d'entraînement, le réseau est fourni en variables d'entrées mais non en variables de sortie. Le système doit décider de lui-même quelles caractéristiques il utilisera pour grouper les variables d'entrées. Cette technique est souvent reconnue comme étant de type « self-organization » ou d'adaptation.

1.5.1.3 GÉNÉRALISATION ET PERFORMANCE DE L'ALGORITHME

Un réseau est qualifié de bien généralisé quand la relation entre les variables d'entrée et de sortie programmées par le réseau est correcte pour un modèle jamais utilisé dans la création ou l'entraînement du réseau.

La généralisation est influencée par trois facteurs :

1. La grandeur et l'efficacité des séries d'entraînements.
2. L'architecture du réseau.
3. La complexité physique du problème.

Le nombre de série d'entraînements requis pour une bonne généralisation est donnée par la relation suivante [3] :

$$N > W/\varepsilon \quad \text{Éq. 1.2}$$

où : W = nombre total de poids synaptique dans le réseau

ε = fraction d'erreur permise sur le test

Voici finalement quelques conseils recommandés pour mieux faire performer l'algorithme de propagation inverse [3] :

1. On aura de meilleures performances au point de vue du nombre d'itérations et de l'apprentissage avec une courbe d'activation asymétrique.
2. Il est important de choisir des valeurs de réponses désirées étant comprises à l'intérieur de la fonction d'activation de la sigmoïde.
3. L'initialisation des poids synaptiques et du seuil d'activation du réseau devrait être uniformément distribuée à l'intérieur d'une petite valeur d'écart. Il est suggéré de considérer l'écart suivant :

$$(-2.4/F_i, 2.4/F_i)$$

où : F_i = nombre total de variable d'entrée

4. Dans le cas des réseaux avec niveaux intermédiaires, il est préférable d'avoir un paramètre de taux d'apprentissage (η) plus petit pour les niveaux finaux que sur les niveaux de départ.
5. Utiliser la méthode échantillon par échantillon lors de l'exécution de l'algorithme.
6. L'ordre des exemples d'entraînement pour chaque série doit se faire aléatoirement pour améliorer la vitesse de convergence.
7. Donner une approximation de la fonction à trouver en donnant des conseils, si possible, au système dans le but d'accélérer la recherche de la fonction.

1.6 LIMITES ET DÉLIMITATIONS DE LA RECHERCHE

Les limites ou limitations de notre recherche sont des restrictions involontaires, des choses hors de notre contrôle en tant que chercheur. Pour cette recherche nous en rencontrerons, c'est certain.

Les quelques limitations pouvant potentiellement survenir sont par rapport à la disponibilité machine. Pour ce qui est du reste, tout devrait être dans les limites du possible.

Les délimitations sont en fait des restrictions volontaires de notre part. Ces délimitations cadrent l'étendue de la recherche. De cette façon, il est assuré de donner des résultats en fonction des objectifs visés.

Lors de cette recherche, l'accent sera mis sur l'étude de la qualité de la formation du matelas seulement, non de la culotte en entier.

Avec un nombre imposant de variables indépendantes, il faudra axer les recherches sur les variables mesurables donc des variables quantitatives.

À cause des horaires de production de plus en plus achalandés et du coût élevé que peut représenter les déchets causés par les différents essais « machine », un maximum de seize expériences peuvent être effectuées.

Pour tout de suite, il faut se limiter à établir un réseau de neurones qui généralise les caractéristiques qualitatives du produit. Si le temps le permet, il pourra être possible d'essayer de bâtir un réseau qui généralisera les variables d'ajustement de la machine, soit un espèce de réseau fonctionnant à l'inverse.

CHAPITRE II

RECHERCHE LITTÉRAIRE

ORGANISATION DU CHAPITRE

Le chapitre de la recherche littéraire en est un où le chercheur démontre son habileté de fouineur et de débrouillardise pour aller chercher les informations essentielles typiques à sa recherche. Ces informations sont une base essentielle pour le cheminement de la recherche et ils déterminent l'étendue exacte de cette dernière.

Tout d'abord, dans cette section, la pertinence et l'originalité de cette recherche seront décrites. Un bref historique des réseaux de neurones ainsi que les domaines couverts par cette technologie y seront présentés. Il sera possible aussi de voir qu'est-ce qui justifie l'emploi des réseaux de neurones.

Sera ensuite présenté un sommaire des articles parcourus. On pourra s'apercevoir que bien souvent, la lecture d'une tonne d'articles ne donne pas nécessairement une tonne d'informations pratiques. De tout ce qui a été lu, il est possible de diviser l'information en deux grandes catégories. D'abord dans un premier temps, il sera possible de voir les articles traitant de la base des configurations des réseaux de neurones. Cette catégorie d'articles présente vraiment l'information de base sur les réseaux de neurones. Ensuite, il sera question des articles qui vont un peu plus loin dans les explications et qui donnent des informations plus susceptibles d'aider le déroulement de la recherche ainsi que l'atteinte optimale des résultats.

En poursuivant plus loin, il sera question des articles portant sur les modèles des plans d'expérimentations. Ces modèles sont, pour la plupart, des plans éprouvés qui fonctionnent depuis très longtemps. La venue de nouveauté sera donc plus difficile à trouver.

En dernier lieu, il sera question des avenues du futur dans la technologie des réseaux de neurones. La technologie des RDN étant jeune, il reste beaucoup de place à l'imagination pour des développements tout aussi divers les uns que les autres. Les algorithmes seront alors à l'honneur. Dans un premier temps, il sera question des algorithmes génétiques et tout ce qui concerne l'optimisation des RDN. Enfin, nous verrons deux autres types d'algorithmes, ceux-là un peu plus secondaires, les algorithmes de Quasi-Newton et de Simplex.

2.1 PERTINENCE ET ORIGINALITÉ

Pendant longtemps, les réseaux de neurones ont été vendus comme étant la révolution du futur dans le domaine de la programmation. Ils sont, en fait, des mécanismes d'auto-apprentissage qui ne requiert pas de talent particulier de programmeur traditionnel. Tel que montré dans [3], à son tout début, vers la fin des

années 50, le « perceptron simple » développée par Rosenblatt, un neuro-biologiste de Cornell, fut une révolution dans le monde de la programmation. Malheureusement, les grands espoirs que les entreprises eurent envers le perceptron furent démolis par deux mathématiciens, Minsky et Papert qui démontrèrent les limites théoriques du « perceptron simple ».

Ce qui fait aujourd'hui la pertinence des réseaux de neurones est sûrement l'arrivée du réseau à propagation inverse. Ce type de réseau, développé au début des années 70 par différentes sources, est venu combler les différentes lacunes que pouvait posséder le « perceptron simple ». La pertinence peut se définir comme étant une preuve que la recherche mérite d'être effectuée. Jusqu'à preuve du contraire, le réseau à propagation inverse se veut la méthode la plus répandue d'analyse de données par programmation et la plus efficace si nous considérons les réseaux de type prédictif, ce qui est présentement notre cas.

La plus grande force des réseaux de neurones réside par contre dans l'originalité des solutions qu'ils peuvent apporter. Les réseaux de neurones peuvent servir pour différents usages; prédictions, classifications, associations de données, la conceptualisation de données ou le filtrage de données. Le Tableau 2.1 donne un bon aperçu de tous les types de réseaux disponibles en fonction des usages désirés.

Un autre aspect de l'originalité des réseaux de neurones est leur habileté et leur force à fournir des solutions aux problèmes non linéaires souvent mal définis ou mal connus. Les régressions simples ou multiples peuvent à la limite aider si la modélisation du problème s'interpose de façon plutôt linéaire et se traite avec une variable de sortie à la fois. Le grand avantage et l'originalité du réseau de neurones vis-à-vis la régression est le suivant ; il est possible avec le réseau de neurones de traiter plusieurs variables d'entrées et de relier à ces mêmes données une série de variables de sortie. Donc, n'importe quelle variable d'entrée peut avoir un impact sur n'importe quelle variable de sortie en un même temps. Avec les régressions, nous devons nous limiter à l'analyse d'une seule variable de sortie à la fois.

Il est maintenant logique de croire que ce type d'outil pour le type de recherche dont il est question est tout à fait désigné et pertinent. Finalement, l'originalité des réseaux de neurones peut se définir par leur flexibilité à traiter différents types de cas et à traiter plusieurs variables de sortie en même temps.

2.2 VUE D'ENSEMBLE DES ARTICLES

Tel que décrit précédemment dans le texte, un certain nombre d'articles traitant des réseaux de neurones sont apparus dans le domaine des pâtes et papiers mais peu étaient reliés au domaine précis de la présente recherche. Dans les trente-cinq à quarante articles qu'il a été possible de lire, environ une dizaine tout au plus se rapprochaient du domaine étudié. Enfin, aucun article pour le domaine d'étude exact, soit la défibrillation secondaire de la pâte cellulosique, ne fut trouvé. Donc, tout est nouveau dans ce domaine particulier.

Type de réseau	Réseaux	Utilisation du réseau
Prédiction	<ul style="list-style-type: none"> • Propagation inverse • Delta Bar Delta • Delta Bar Delta étendue • Recherche aléatoire dirigée • Réseau de Neurones à haut niveau d'ordre • Mappage auto-organisé à l'intérieur de la propagation inverse 	Utilisation de valeurs d'entrée pour prédire des valeurs de sortie (e.g. choisir le meilleur équipement sur le marché, prédire la température, identifier des gens avec des risques de cancer etc.).
Classification	<ul style="list-style-type: none"> • Quantification du vecteur d'apprentissage • Propagation opposée • Réseaux de Neurones probabilistes 	Utilisation des valeurs d'entrées pour déterminer la classification (e.g. est-ce que la valeur d'entrée est la lettre A, est-ce que la tache provenant des données vidéo provient d'un plan et quel sorte de plan est-ce?)
Association de données	<ul style="list-style-type: none"> • Hopfield • Machine de Boltzmann • Réseau de Hamming • Mémoire associative bidirectionnelle • Reconnaissance de comportement spatio-temporelle 	Comme la classification mais il reconnaît aussi des données contenant des erreurs (e.g. n'identifie pas seulement les caractères qui sont scannés mais identifie quand le scanner ne fonctionne pas correctement).
Conceptualisation de données	<ul style="list-style-type: none"> • Réseau de résonance adaptatif • Mappage auto-organisé 	Analyse des valeurs d'entrée de sorte que la relation de groupement peut être déduite (e.g. extraction d'une base de données de noms pouvant être plus aptes à acheter un tel produit).
Filtrage de données	<ul style="list-style-type: none"> • Recirculation 	Égalisation de valeurs d'entrées (e.g. enlever le bruit de fond provenant d'un signal téléphonique).

TABLEAU 2.1 : SÉLECTION DE RÉSEAUX. [1]

Les sources d'information traitant des réseaux de neurones sont aussi de plus en plus diverses. Il existe, bien sûr les articles conventionnels dont les sources se situent dans les universités ou dans les centres gouvernementaux de recherches. Dans notre temps présent, il existe aussi l'Internet qui se veut une source inépuisable d'information. L'inconvénient majeur avec l'Internet est que les informations de qualité, disponibles au grand public, sont plutôt minces. Avec ce type de véhicule d'information c'est le signe du dollar qui prime, plus on a de dollars, meilleures sont les possibilités d'obtenir des informations de qualité. C'est finalement dommage pour nous, pauvres chercheurs étudiants. Enfin, il a été possible aussi d'assister à une conférence sur un sujet très près de la technologie des RDN. Ce type de source d'information, bien qu'il ne soit pas toujours selon la nature exacte de notre recherche, permet souvent d'acquérir des connaissances qui, tôt ou tard, donneront des idées sur notre domaine d'étude.

A partir de tout ce qui a été lu pendant cette recherche littéraire voici maintenant au Tableau 2.2 quelques titres rencontrés qui donnent des exemples d'application dans des domaines connexes. À la sous-section suivante, il sera possible de connaître l'analyse de quelques-uns de ces articles. Le but de cet exercice est de démontrer que même avec des articles plus ou moins reliés au domaine d'étude, il est possible d'aller chercher des informations de base intéressantes pour les appliquer dans notre domaine d'étude précis.

1. Modeling coated paper properties : application of neural networks [4].
2. The artificial neural networks and the drying process modeling [5].
3. Neural network model for paper forming process [6].
4. Modeling and optimization of pulp and paper processes using neural networks [7].
5. Using neural networks to diagnose web break on a newsprint paper machine [8].
6. A neural network for modeling pulp process [9].

TABLEAU 2.2. LISTE DES ARTICLES.

2.2.1 ARTICLES SUR LA BASE DES RDN.

De tous ces titres déjà énumérés au Tableau 2.2, faisons maintenant l'analyse plus en profondeur de deux d'entre eux. Prenons par exemple le titre deux et le titre cinq.

Tout d'abord, le titre deux, "The artificial neural networks and the drying process modeling" [5]. Dans cet article, on tente de modéliser les interactions entre la température de l'air chaud, la vitesse de l'air et le ratio (lit haut fixe/diamètre de l'assécheur) de la pâte de papier pour trouver des valeurs de sortie sur le taux d'assèchement et de l'humidité.

Dans cet article on mentionne que la fonction « seuil choisi » fut celle de la sigmoïde mais de version plus versatile que l'originale. La courbe devenant légèrement plus linéaire que l'originale, elle est définie par :

$$f(x) = 1 / (1 + (e^{-\alpha x} / \beta)) \quad \text{Éq. 2.1}$$

Cette recherche étant une recherche de type prédictive, l'auteur a pris soin de sélectionner l'algorithme de propagation inverse pour faire sa programmation. On dit aussi que le réseau de neurones fut choisi par rapport à la régression linéaire classique à cause de sa capacité plus grande de généralisation. Aussi, l'auteur considère que la phase la plus importante et celle sur laquelle nous devrions le plus nous attarder est la phase d'apprentissage.

Dans cet article, il a aussi été question des niveaux intermédiaires. On y explique que la sélection du nombre de niveau se fait de façon « essais erreurs ». L'auteur a fait une étude avec différentes séries de niveaux intermédiaires en changeant le nombre d'éléments par niveau et le nombre de niveaux. Il a aussi défini un temps d'apprentissage spécifique (TAS) pour chaque cas, soit le ratio du temps d'apprentissage sur le nombre d'éléments au total par niveau. À la suite du tracé d'un graphique, l'auteur a pu prendre la bonne décision quant à l'architecture de son réseau. Deux conclusions sortiront de cette expérience. D'abord, deux niveaux intermédiaires ou plus ralentiront la convergence du procédé. Finalement, un nombre total d'éléments sans cesse grandissants pour chaque niveau intermédiaire, aura pour effet de diminuer l'importance de la topologie du réseau.

Enfin, voyons le titre cinq, "Using neural networks to diagnose web breaks on a newsprint paper machine" [8]. Celui-ci fait la description d'un cas typique d'entreprise pris avec un problème de bris de tissu et utilisant un réseau de neurones ainsi que les statistiques conventionnelles pour détecter les bris potentiels.

Encore une fois ici, il s'agit d'un problème à caractère prédictif. À partir d'une série de variables susceptibles de causer les bris, l'auteur a fait un criblage de ces différentes variables pour ne garder que les plus importantes. À partir des variables majeures, il a donc bâti son réseau. L'article ne dit pas cependant si l'auteur a fait une analyse de variabilité à partir de données pris sur le procédé ou quel plan expérimental il a pu prendre.

Pour ce qui est de la mécanique du réseau maintenant, l'article ne le dit pas mot à mot mais selon les graphiques et les diverses descriptions du réseau, il s'agirait bien d'un réseau de type à propagation inverse. On ne parle pas beaucoup de la façon dont le réseau est monté mais on dit que par diverses combinaisons via « essais erreurs », on réussit à trouver l'architecture optimale. Encore une fois, pour cette recherche, la fonction de seuil choisie fut celle de la sigmoïde classique.

En conclusion, ces deux articles ne contiennent pas d'éléments vraiment susceptibles d'aider pour le domaine d'application auquel la recherche s'applique. Par contre dans ces deux articles, comme dans la plupart des autres articles lus, plusieurs caractéristiques de réseaux reviennent, donnant ainsi des indices à savoir à quoi devrait ressembler un réseau de neurones et quelle configuration fait bien fonctionner le système. Les configurations de base étant maintenant explorées, il restera à voir

comment il sera possible d'appliquer les techniques de recherches pour trouver des résultats qui veulent dire quelque chose, c'est ce dont la prochaine section traitera.

2.2.2 ARTICLES UTILISES AU DEROULEMENT DE LA RECHERCHE

C'est avec ces genres d'articles que la recherche effectuée prend toute sa valeur ajoutée. Chaque article de ce genre donne à la recherche des outils de validation de résultats ou de simplification de la tâche. Ce type d'article aide finalement à l'obtention d'une recherche plus crédible.

Dans la série des articles qui ont été lus pour cette présente recherche, notons d'abord un article de Louis W. Glorfeld de l'université des affaires d'Arkansas intitulée "A methodology for simplification and interpretation of backpropagation-based neural network models" [10].

Le contenu de ce dernier article est tout à fait à propos avec le type de recherche présentement fait. Dans un premier temps, on y explique une méthode d'optimisation des variables indépendantes (variables d'entrée) en fonction de leurs impacts sur le changement des variables dépendantes (variables de sortie). En fait, on y développe une méthode qui fournit des explications sur la façon dont un réseau de neurones utilise ses variables d'entrées pour produire une valeur de sortie prédite. Alors, n'importe quel utilisateur pourra, au moins, avoir une certaine compréhension des bases de décisions prises par le réseau de neurones.

La méthode derrière cette optimisation du nombre des variables indépendantes est accomplie par l'utilisation de la validation croisée "V-fold" ou "V-fold cross-validation" [11] associée avec l'utilisation d'une équation heuristique mesurant l'erreur standard sur les résultats de ladite validation croisée. Un bénéfice certain de cette optimisation des variables indépendantes est la meilleure généralisation par rapport aux données tests lors de l'entraînement des variables. Le V de "V-fold" indique le nombre de fois qu'une itération de l'équation heuristique se produit.

Selon une forme de cette dernière méthodologie, chaque variable indépendante, sauf celle mise en test, est gardée en valeur constante. La variable à l'étude subit quant à elle une variation dans le temps. L'effet de cette variation sur le signal de sortie est noté. Ce processus est répété pour chaque variable indépendante et mène vers une classification selon chaque contribution apportée sur les variables de sortie. L'importance de la variable d'entrée "VI" est calculée à partir de la formule de Garson pour chaque $P_{i\text{ème}}$ variable d'entrée comme:

$$VI_{xp} = \frac{\sum [(|I|_{pj} / \sum |I|_{pj,k}) |O|_j]}{\sum (\sum [(|I|_{pi,j} / \sum |I|_{pi,j,k}) |Q|_j])} \quad \text{Éq. 2.2}$$

numérateur: 1^{re} sommation: $j=1 \rightarrow n_h$ 2^e sommation: $k=1 \rightarrow n_p$
dénominateur: 1^{re} sommation: $i=1 \rightarrow n_p$ 2^e sommation: $j=1 \rightarrow n_p$
3^e sommation: $k=1 \rightarrow n_p$

où: n_p = nombres de variables d'entrées
 n_h = nombres d'éléments au niveau intermédiaire

$|I|_{pj}$ = valeur absolue du poids au niveau intermédiaire correspondant à la $P_{i\text{ème}}$ valeur d'entrée et au $j_{\text{ème}}$ élément du niveau intermédiaire

$|O|_j$ = valeur absolue du poids de la variable de sortie correspondant au $j_{\text{ème}}$ élément du niveau intermédiaire

Il est à noter que le calcul ne prend pas en compte le biais ou la valeur constante du poids résultant de la procédure de propagation inverse.

Donc, cette procédure résulte en une compréhension plus facile de l'interprétation à savoir comment un réseau à propagation inverse utilise ses valeurs d'entrées pour produire les valeurs de prédictions à la sortie.

Enfin dans ce même article [10], on traite d'une méthode pour faire une optimisation de l'entraînement des variables. Quand on sait que l'entraînement des variables indépendantes est une étape cruciale dans la bonne réussite de la généralisation des valeurs d'un réseau de neurones, il vaut la peine de s'y attarder.

Cette méthodologie est à la base assez standard. Cette méthodologie est aussi connue sous le nom de validation croisée ou « cross-validation ». Cette méthodologie standard implique de séparer les données d'entraînement en deux groupes. D'abord l'utilisation de la première portion au développement du réseau de neurones et l'autre portion pour valider les performances du réseau.

Ce qui sera suggéré maintenant par Glorfeld pour améliorer l'optimisation de l'entraînement et la modélisation de la zone à étudier est l'utilisation du même "V-fold cross-validation". Le fonctionnement est encore ici très simple.

1. À partir du groupe complet de données d'entraînement, déterminer un certain nombre de groupes participant à l'entraînement du réseau, appelons ce groupe « G ». Plus la valeur de « G » sera grande moins l'erreur reliée à l'estimation du modèle sera grande.
2. Lors de la première passe d'entraînement, prendre un groupe égal à « G-1 » pour faire l'entraînement du réseau et garder le dernier groupe pour valider les résultats.
3. Pour l'entraînement subséquent, introduire le groupe de validation de l'étape deux à l'intérieur du groupe d'entraînement « G-1 » et sortir un nouveau groupe pour faire la validation des résultats.
4. Répéter l'étape trois jusqu'à ce que chaque groupe de variables d'entraînement ait été au moins une fois à l'étape de validation des résultats.

5. Quand toutes les validations croisées auront été effectuées à l'étape quatre, on regroupera alors tous les groupes de variables d'entraînement et on s'en servira pour l'entraînement final du réseau de neurones en vue de l'essai avec de nouvelles données jamais rencontrées. Les performances futures du réseau seront à l'image des entraînements sur le groupe « G » des variables d'entraînement.

Pour un seul article, ça fait beaucoup de nouvelles théories à appliquer pour cette recherche. Chaque information assimilée et incluse dans la recherche ajoute un peu plus de crédibilité aux résultats obtenus.

Un deuxième article, qui est tout aussi pertinent, est celui de Jacques Bourquin [12] de l'université de Basle en Suisse. Cet article s'intitule "Comparison of ANN with classical modelling techniques using different experimental designs and data from a galenical study on a solid dosage form". Un titre très long contenant de petites idées de base pratiques pour bien optimiser la généralisation du réseau de neurones à l'entraînement.

L'idée de base qui a été retenue de cet article se situe au niveau du calcul des erreurs sur les valeurs trouvées lors des expérimentations. En fait, il ne sert à rien de faire apprendre un réseau de neurone à un degré de précision supérieur au degré auquel les expériences « machine » sont parvenues.

Pour comparer les performances de chaque série d'expériences entre elles, le coefficient de corrélation au carré " R-square " ou R^2 est calculé pour chaque modèle rencontré. L'équation de cette corrélation au carré est donnée par:

$$R^2 = 1 - (SSE/TSS) \quad \text{Éq. 2.3}$$

où: SSE = Somme des erreurs au carré entre la prédiction du modèle et les vraies valeurs visées.

TSS = Le total des erreurs au carré. (TSS = SSE+SSM)

SSM = Somme des erreurs au carré entre la prédiction du modèle et la moyenne des vraies valeurs visées.

Conséquemment, l'ajustement parfait entre ces deux types de valeurs existe quand $R^2 = 1$ tandis que l'ajustement nulle existe avec $R^2 = 0$.

Avant cette étape, à partir des mesures expérimentales trouvées, pour chacune des réponses obtenues, le meilleur coefficient de corrélation au carré (max R^2) est calculé pour contrôler la performance des différents modèles à étudier. Le meilleur coefficient de corrélation au carré (max R^2) est donné en fonction des mesures expérimentales et est défini comme suit:

$$\max R^2 = 1 - (S^2 / S_0^2) \quad \text{Éq. 2.4}$$

où: S^2 = Variance moyenne de la mesure répétée
 S_0^2 = Variance des moyennes mesurées

Cette équation permet ainsi aux différents modèles à l'étude de ne montrer aucune tendance de sur-apprentissage tant et aussi longtemps que le coefficient " R^2 " reste inférieur au coefficient " $\max R^2$ ".

En continuant sur cette voie, l'erreur sur les données tests soit l'erreur moyenne au carré " MSE " (où $MSE = SSE/n$) est vérifiée et l'entraînement arrête aussitôt que cette valeur de MSE n'ira plus en descendant mais en augmentant. Ce sera alors un signe que l'entraînement fait un sur-apprentissage du modèle.

2.3 LES PLANS EXPÉRIMENTAUX

La théorie des plans expérimentaux ne date pas d'hier. En fait certaines théories remontent à très loin. Le fondement des plans expérimentaux se retrouve au travers des mathématiques et des statistiques. Ces deux domaines étant des sciences exactes, il devient difficile de retrouver des nouveautés parus via des articles scientifiques.

Lors de la recherche d'articles scientifiques portant sur les réseaux de neurones, il n'est jamais question des plans expérimentaux et du lien important qui existe avec les réseaux de neurones pour le traitement des données. Pourtant, les gens du domaine mentionnent à plusieurs endroits que la cueillette des données expérimentales est une partie importante du succès de l'interprétation des résultats par les réseaux de neurones. Alors, comment oublier les plans expérimentaux qui y sont directement reliés?

Finalement, le meilleur endroit pour trouver des informations sur les plans expérimentaux reste dans les livres [2,13]. À partir de là, le chercheur peut choisir son plan en conséquence et se familiariser avec les degrés de résolution, le nombre de niveaux, le nombre d'expériences à choisir etc.

Maintenant, avec le contenu des articles vus plus haut et la bonne compréhension du fonctionnement des plans expérimentaux, le chercheur se sentira pleinement capable de mener à bien son expérience.

2.4 LES AVENUES INEXPLORÉES

Au début de cette présente recherche, des limitations avaient été imposées par le chercheur pour différentes raisons. Le domaine technologique des réseaux de neurones devient de plus en plus large au fur et à mesure que le temps avance. De nombreuses avenues n'ont pas été explorées, non par manque d'intérêt mais plutôt par

manque de capacité. Ainsi, la présente recherche ne s'est limitée qu'à la partie prédictive des réseaux de neurones avec l'algorithme à propagation inverse. D'autres avenues comme la classification, la conceptualisation de données ou l'association des données auraient pu être étudiées avec différents autres algorithmes comme celui de Hopfield ou " Radial Basis Function ".

Par contre, le développement de l'avenir au niveau des réseaux de neurones se situe dans les algorithmes d'optimisation des résultats. Quand ces outils auront été pleinement développés et qu'ils seront éprouvés, la technologie des réseaux de neurones deviendra quelque chose de très puissant.

Les premiers algorithmes commencent à émerger tranquillement pour donner une certaine forme d'optimisation. Le premier algorithme rencontré sera celui de l'algorithme génétique. Cet algorithme est très bien conçu en fonction des réseaux de neurones et des variables à sorties multiples.

Ensuite deux autres algorithmes, un peu moins puissants et flexibles, seront montrés. D'abord l'algorithme de Quasi-Newton, qui est conçu également en fonction des variables à sorties multiples et l'algorithme de Simplex qui lui, s'applique uniquement avec les équations de régression.

2.4.1 LES ALGORITHMES GENETIQUES

Dans la catégorie des nouvelles avenues de développement en réseau de neurones, l'algorithme génétique est un outil fort utile pour le développement des modules d'optimisation. Bien que l'algorithme génétique puisse être utile sous d'autres formes comme par exemple pour définir l'acceptation de seuil minimal « threshold acceptance », l'optimisation des solutions obtenues par réseau de neurones se veut le développement le plus attendu pour rendre cette technologie vers un autre niveau de puissance [14,15,16]. Par optimisation, il n'est pas seulement question d'optimisation des valeurs de sortie, il peut aussi être question de l'optimisation du nombre de variables d'entrée ainsi que l'optimisation de l'architecture du réseau en général. Cet outil se veut donc très prometteur.

Selon l'article en [15], ce qui fait le lien entre l'algorithme génétique et les réseaux de neurones se situe au niveau de leur philosophie de fonctionnement. Autant l'un que l'autre fonctionne selon une inspiration biologique, c'est-à-dire selon une évolution génétique. Les algorithmes fonctionnent de façon similaire soit de façon itérative en faisant converger des variables vers une région optimale du domaine étudié. Ces valeurs de variables sont appelées à changer au travers du temps et seront toujours en constante évolution.

Normalement regroupées sous le terme d'algorithmes évolutionnistes ou calculs d'évolutions, ces deux dernières appellations contiennent des domaines comme les algorithmes génétiques, les stratégies évolutionnistes, la programmation évolutionniste et la programmation génétique.

Dans le domaine qui nous intéresse particulièrement, selon l'article [16], les algorithmes génétiques sont des procédures itératives qui consistent en une définition d'individus à population de grosseur toujours constante. Chacun de ces individus, appelés aussi « génome », sont représentés par une chaîne de symboles distincts et encodés en fonction d'une solution possible pour un problème dans un espace donnée. Cet espace problème est aussi appelé « espace de recherche » et comprend toutes les solutions possibles sur un problème donné. Généralement parlant, l'algorithme génétique est appliqué à des espaces qui sont généralement trop grands pour une recherche normale. Les symboles alphabétiques utilisés dans le code sont souvent de nature binaire à cause de certains avantages que la programmation peut apporter. Ces dernières années, les représentations ont été étendues pour inclure l'encodage à base de caractères alphanumériques, en valeurs réelles et aussi en représentations sous forme d'arborescence.

Le fonctionnement de l'algorithme génétique standard procède comme suit [15]:

1. Une population initiale d'individus est générée de façon aléatoire ou de façon heuristique.
2. À chaque nouveau pas menant vers une nouvelle évolution sur la solution, aussi connu sous le terme « génération », les individus de la population courante sont alors décodés et évalués en fonction d'un critère qualitatif prédéfini se référant à une fonction mathématique évoquant la justesse des approximations « fitness function ».
3. Pour former une nouvelle population d'individus ou « prochaine génération », les individus sont sélectionnés en fonction de leurs degrés d'approximations sur l'équation modèle recherché ou "equation fitness".
4. Plusieurs procédures de sélection sont présentement en utilisation, une des plus simples étant celle d'Holland où les individus sont sélectionnés selon une probabilité proportionnelle à leurs exactitudes relatives sur l'équation modèle. Cette méthode assure que le nombre de fois qu'un individu sera choisi en prochaine génération est proportionnel à sa performance relative dans la population. Ainsi, les bons individus ont une meilleure chance de reproduction pendant que les moins bons ont plus tendance à disparaître.

Le processus de sélection pour les prochaines générations n'introduit pas de nouveaux individus à l'intérieur de la présente population donc, il n'essaie pas de trouver de nouveaux points dans l'espace de recherche. Cette transformation vers la prochaine génération est produite via des opérateurs spécifiques.

Parmi les opérateurs les plus utilisés et les plus connus, les croisements et les mutations sont utilisées. Les croisements sont effectués avec une probabilité $p_{\text{croisement}}$

entre deux individus sélectionnés appelés « parents ». Ces parents échangent une partie de leur génome, c'est-à-dire l'encodage, pour former deux nouveaux individus appelés « progéniture » « offsprings ». Dans sa plus simple forme, les chaînes de codes primitifs sont échangées suite à une sélection aléatoire de point de croisement. Ce type d'opération tend à provoquer un processus d'évolution qui se déplacera vers des régions plus prometteuses de l'espace de recherche. Si on connaît déjà un peu la théorie sur l'algorithme de propagation inverse, bien que ce ne soit pas tout à fait pareil, il est quand même possible de faire une analogie de l'utilité de cet opérateur de croisement avec le taux d'apprentissage.

L'opérateur de mutation, quant à lui, est introduit pour prévenir les convergences prématurées sur des points optimaux locaux en échantillonnant de façon aléatoire de nouveaux points dans l'espace de recherche. Cette fonctionnalité est produite en changeant des bits sur l'individu de façon aléatoire selon une probabilité p_{mut} . Cet opérateur agit en quelque sorte un peu comme l'opérateur de momentum actuellement utilisé avec l'algorithme de propagation inverse. Les algorithmes génétiques sont des processus itératifs qui ne garantissent cependant pas une convergence assurée. La condition pour terminer le roulement de l'algorithme doit être spécifiée selon un nombre maximal d'itération ou selon un niveau acceptable de la précision du modèle recherché « acceptable fitness ».

La Figure 2.1, plus bas, montre un exemple sous forme de pseudo-code du fonctionnement d'un algorithme génétique.

```

Début AG
  g:=0 { compteur de génération }
  Initialisation de population P(g)
  Évaluer la population P(g) { i.e., calculer les valeurs de justesse }
  Pendant non fait Faire
    g:=g+1
    Prendre P(g) de P(g-1)
    Croisement de P(g)
    Muter P(g)
    Évaluer P(g)
  Fin Pendant
Fin AG

```

FIGURE 2.1: PSEUDO-CODE DE L'ALGORITHME GÉNÉTIQUE STANDARD. [15]

2.4.2 LES ALGORITHMES DE QUASI-NEWTON ET SIMPLEX

Pour terminer cette section sur les avenues inexplorées, voyons maintenant deux autres types d'algorithmes pouvant être utilisés pour optimiser la recherche de solutions dans l'espace étudié. Ces algorithmes, comme le titre le dit, sont ceux de Quasi-Newton et de Simplex.

2.4.2.1 QUASI-NEWTON

Dans un premier temps, il est question de l'algorithme de Quasi-Newton [17]. La justification de voir cet algorithme en premier vient du fait que ce dernier est plus adaptable aux réseaux de neurones, ce qui est le sujet de la recherche.

Le problème de détermination des paramètres du réseau de neurones, comme par exemple les poids situés sur chaque connexion des neurones, est essentiellement une tâche d'optimisation non linéaire. L'algorithme de propagation inverse, laquelle est distribuée avec une technique du gradient de descente, est la méthode d'entraînement la plus populaire jusqu'à maintenant. Des méthodes encore plus efficaces aujourd'hui incluent des algorithmes comme celui du gradient conjugué et du Quasi-Newton.

L'algorithme de Quasi-Newton voit sa force où la matrice Hessienne devient difficile à calculer ou prend trop de temps à évaluer. Au lieu d'obtenir un estimé de la matrice d'Hessian en un seul point, cette méthode construit graduellement une approximation de la matrice d'Hessian en utilisant un gradient d'information provenant de quelques ou de toutes les itérations précédentes visitées par l'algorithme.

La matrice d'Hessian est à la base une matrice servant à l'approximation des courbes à l'aide de la dérivée première de sa matrice présentée plus bas [18]. La matrice d'Hessian " $\nabla^2 r(x)$ " d'une fonction scalaire $r(x)$ ($x \in \mathbb{R}^2$) est définie par la matrice $n \times n$ construite selon la seconde dérivée partielle.

$$\nabla^2 r(\vec{x}) = \begin{pmatrix} \frac{\partial^2 r(\vec{x})}{\partial x_1^2} & \dots & \frac{\partial^2 r(\vec{x})}{\partial x_1 \partial x_n} \\ \vdots & & \vdots \\ \frac{\partial^2 r(\vec{x})}{\partial x_1 \partial x_n} & \dots & \frac{\partial^2 r(\vec{x})}{\partial x_n^2} \end{pmatrix}.$$

Éq. 2.5

Ce qu'il faut retenir de cet algorithme à notre niveau est que l'utilisation de l'algorithme de Quasi-Newton rend la méthode d'approche pas-à-pas « steepest descent » désuète. Ces deux types d'algorithmes ne requièrent que le calcul de la dérivée première et chacune ne fait que la recherche selon une droite. L'algorithme de Quasi-Newton demande légèrement plus d'opérations lors de son calcul d'itération et en quelque sorte, demande un peu plus de mémoire. Dans presque tous les cas, par contre, ces coûts additionnels sont outre passés par l'avantage d'avoir une convergence supérieure.

2.4.2.2 SIMPLEX DE BASE

La méthode de Simplex est une autre méthode ou algorithme aidant à l'optimisation des solutions trouvées dans le domaine de recherche. La différence de cette méthode par rapport à celle de Quasi-Newton est que Simplex s'applique pour

des modèles se basant sur des régressions linéaires par exemple. Donc, cette méthode est efficace lorsqu'une valeur de sortie seulement sera impliquée par équation. Ici, l'algorithme n'est pas montré en détail, le but de cet exposé étant seulement de démontrer que d'autres algorithmes existent et qu'ils peuvent rendre de bons services selon l'usage requis.

Tout comme avec l'algorithme génétique, selon l'article [19], ce qui relie la méthode de Simplex aux réseaux de neurones se retrouve dans la philosophie de fonctionnement de l'algorithme des recherches de solutions. La méthode de Simplex, tout comme les réseaux de neurones, base son algorithme sur des processus itératifs de recherches dans un certain domaine étudié. Sur une certaine étendue de temps, les deux algorithmes évoluent et donnent des résultats d'approximations toujours plus près de la réalité.

La méthode d'optimisation de Simplex a été développée originalement pour des opérations évolutionnistes et fonctionne très bien pour ces usages. Il est assez motivant pour un chercheur d'utiliser cette méthode d'optimisation puisque seulement quelques essais « machine » sont nécessaires pour débiter l'analyse.

La méthode d'optimisation de Simplex est spécialement appropriée quand [19] :

1. La performance du procédé change au cours du temps.
2. Quand trois variables de contrôle ou plus changent d'état au cours d'un temps donné.
3. Le procédé requiert une optimisation renouvelée suite à un changement de lot de matériel.

La méthode d'optimisation de Simplex est basée sur un design initial comprenant $k+1$ essai où k se veut être le nombre de variables à l'étude. Une figure géométrique dans l'espace $k+1$ dans un espace dimensionnel k est appelé Simplex. Chaque coin de la figure créée est appelé « sommet ou vertex ». La Figure 2.2 montre un exemple de figure créée à partir de deux variables de contrôle.

Après l'essai initial, le processus de Simplex devient séquentiel avec l'addition et l'évaluation d'un nouvel essai à chaque fois. Le Simplex recherche systématiquement le meilleur niveau d'optimisation pour les variables de contrôles. Le processus d'optimisation se termine quand l'objectif relié à l'optimisation est atteint ou quand les réponses trouvées ne pourront être améliorées.




FIGURE 2.2 REPRÉSENTATION D'UN SIMPLEX STANDARD. [19]

2.4.2.3 **SIMPLEX MODIFIÉ**

La méthode modifiée de Simplex a beaucoup en commun avec le Simplex de base mais peut ajuster son périmètre triangulaire et sa taille en fonction des réponses trouvées à chaque itération.

Ces nouvelles améliorations font en sorte que le Simplex modifié [19]:

- Subit une expansion dans une direction où les conditions sont plus favorables.

Ou

- Subit une contraction si le déplacement se fait par rapport à une direction moins favorable.

Ces procédures d'expansion et de contraction permettent au Simplex modifié de faire, dans un même temps, une accélération vers une direction favorable de recherche et de s'installer dans une zone optimale selon les résultats recherchés. Par conséquent, la méthode modifiée de Simplex atteint habituellement la région optimale plus rapidement que la plupart des méthodes de base prises couramment.

La Figure 2.3 montre un exemple de déplacement des différents périmètres triangulaires en fonction des nombreux déplacements sur un temps donné. On remarque que le degré de contraction de chaque périmètre dépend de la « favorabilité » de la réponse fournie lors de chaque itération.




FIGURE 2.3. SÉQUENCE D'OPTIMISATION TYPIQUE D'UN SIMPLEX MODIFIÉ. [19]

2.5 POSITIONNEMENT FACE À LA RECHERCHE LITTÉRAIRE

Connaissant déjà une bonne partie de la lourde tâche d'analyse à faire sur les données recueillies lors des essais « machine » et du montage du réseau de neurones avec ses différents éléments de base, il est de mise, lors de cette recherche, d'essayer de minimiser les erreurs d'interprétation et d'optimisation des résultats.

En fonction de tous les articles lus pendant cette période de familiarisation avec les réseaux de neurones, il serait logique de commencer le montage du réseau de neurones en se fiant sur les éléments de base les plus utilisés parmi les recherches déjà en cours au travers le monde. Parmi les éléments les plus utilisés notons :

- L'algorithme de propagation inverse.
- La fonction de transfert de forme tangente hyperbolique.
- L'usage d'un taux d'apprentissage (η) se situant aux alentours de 0.3.
- L'ajout d'un momentum au taux d'apprentissage.

De même, l'analyse des résultats provenant du réseau de neurones pourra être conséquente à certains articles rencontrés comme par exemple:

- L'utilisation de la technique du " V-fold cross-validation " de Glorfeld pour la détermination de la validité des variables tests par rapport aux résultats obtenus par calculs des réseaux de neurones [10,11].
- L'utilisation des équations de Bourquin pour déterminer la variabilité dans les résultats obtenus sur machine. Il est alors possible de déterminer l'approximation maximale via le calcul d'erreurs en fonction des équations de corrélation (R^2) et ($\max R^2$) [12].

Bien sûr, toute cette lecture apporte beaucoup de nouvelles notions théoriques que le chercheur peut inclure dans ses analyses. Souvent, un article est fait en fonction d'un type de recherche particulier et ne peut peut-être pas fonctionner avec la recherche actuelle. Il est alors du ressort du chercheur de prendre ces nouvelles notions théoriques et de les adapter à sa propre recherche. C'est notre cas pour cette recherche. Les notions vues dans les articles s'y retrouveront mais non pas nécessairement mot pour mot. Il y aura adaptation de cette théorie à notre recherche. C'est ce qui fait le succès des bonnes recherches... nous croyons.

Pour ce qui est des autres sources d'informations recueillies, c'est-à-dire tous les autres articles jugés moins intéressants pour la recherche, ils seront quand même mentionnés à la fin du document sous le titre « Bibliographie ». Ces articles n'ont pas contribué à cette recherche mais leur lecture à quand même permis d'étendre mes horizons sur ce qui se fait dans les autres domaines connexes.

CHAPITRE III

DESCRIPTION DE LA MÉTHODOLOGIE UTILISÉE

ORGANISATION DU CHAPITRE

Dans les pages qui suivront, le lecteur sera en mesure de découvrir comment s'est effectuée la recherche sur la « Modélisation de la défibration secondaire de la pâte cellulosique à l'aide d'un réseau de neurones ».

Dans un premier temps, il sera montré de quelle façon s'est organisée la recherche. D'une façon tout à fait simple, les principales étapes parcourues lors de la recherche seront énumérées. Cette partie de chapitre donnera un rapide coup d'œil sur ce qui sera vu un peu plus loin dans les autres parties de chapitre.

Par la suite, il sera vu un peu plus en détail chaque étape qui a mené à l'atteinte des objectifs de la recherche.

À la suite de la lecture complète de ce chapitre le lecteur sera en mesure de connaître parfaitement le cheminement pris pour la réalisation de la recherche. Il sera alors en mesure de beaucoup mieux apprécier le contenu du chapitre subséquent qui traitera de l'analyse des résultats.

3.1 ORGANISATION DE LA RECHERCHE

La raison première de ce chapitre est de démontrer quelles sont les différentes étapes poursuivies pour réussir à atteindre les objectifs fixés par le chapitre 1. Voyons sous forme synthétisée les différentes étapes parcourues:

1. Détermination des variables dépendantes et indépendantes à inclure à la recherche.
2. Choix d'un plan expérimental en fonction des variables choisies au numéro un.
3. Conduite des expériences sur machine et enregistrement des données.
4. Analyse et traitement préliminaires des résultats obtenus via les analyses en laboratoire.
5. Analyse de variabilité et de sensibilité par Pareto, appliquée sur les résultats obtenus au numéro quatre.
6. Analyse des mêmes résultats obtenus au numéro quatre par RDN et vérification des résultats en fonction des analyses faites au numéro cinq.
7. Création du tableau final des résultats et interprétation des résultats.

3.2 DÉTERMINATION DES VARIABLES DÉPENDANTES ET INDÉPENDANTES

La première chose à connaître avant de commencer ce type de recherche est d'identifier les différentes variables indépendantes susceptibles d'avoir un effet immédiat sur les variables qualitatives du matelas à l'étude, soit les variables dépendantes.

Puisque que l'établissement d'un RDN mise aussi sur l'expertise des gens pour son bon fonctionnement, il a été demandé aux gens travaillant sur machine ainsi qu'à certains mécaniciens de dresser une liste des différentes variables indépendantes pouvant avoir un effet sur les caractéristiques qualitatives du matelas à l'étude. Le Tableau 3.1 montre la liste des différentes variables trouvées par ces gens ainsi que celles qui ont finalement été retenues.

<i>Variables suggérées</i>	Oui	Non
1. Nombre de pâtes entrant au broyeur à marteau.	X	
2. Distance entre le « breaker bar » et les lames du broyeur à marteaux.	X	
3. Vitesse d'entrée des pâtes au broyeur à marteaux ou cadence de production.	X	
4. Distance de la brosse égalisatrice par rapport au tambour de formation.	X	
5. Aspiration dans la zone « A » du tambour de formation.	X	
6. Le jet de décollement du matelas sur le tambour de formation		X
7. La propreté des pochettes de formation du matelas.		X
8. Pression du dépoussiéreur Osprey sur le tambour de formation.		X
9. L'effet de calendrage progressif.		X
10. L'humidité sur les pâtes avant le broyage		X
11. Nombre de marteaux à l'intérieur du broyeur à marteaux.		X
12. L'état de la brosse égalisatrice.		X
13. Le sens de rotation de la brosse égalisatrice.		X
14. Les ajustements de Plexiglas à l'intérieur du tambour de formation.		X
15. La forme des Plexiglas entre le tambour de formation et le broyeur à marteaux.		X
16. Aspiration du caisson à l'intérieur du convoyeur situé sous le tambour de formation.		X
17. Le soutien du tapis sous le tambour de formation.		X
18. Distance entre les rouleaux à la calandre de gaufrage.	X	
19. Position du tuyau de super absorbant.	X	
20. Concentration du super absorbant.		X
21. Condition des marteaux au broyeur à marteaux.		X

TABLEAU 3.1: VARIABLES SUGGÉRÉES POUR L'ÉTUDE.

Quelques raisons peuvent expliquer pourquoi seulement sept variables furent choisies parmi tout ce groupe. Premièrement, pour se limiter à un nombre d'essais « machine » raisonnable en fonction du design expérimental choisi, il a fallu limiter les

choix. Aussi, il faut prédire parmi toutes ces variables lesquelles ont les effets les plus distinctifs. Si on prend comme philosophie la loi de Pareto qui dit que 20% des variables choisies expliquent 80% des effets apparaissant, alors il existe quelques variables parmi ces vingt et une qui ont des effets très limités. Avec l'aide de gens ayant une réputation certaine sur la connaissance du fonctionnement de la machine, il a été déterminé que les sept variables, vues plus haut, sont probablement celles ayant le plus d'influence sur les changements des variables dépendantes du matelas à l'étude.

Enfin, pour les variables dépendantes, soit les variables qualitatives, une approche semblable a été effectuée. Cette fois, ce sont les gens du laboratoire qui ont été sollicités. Suite à cette sollicitation six principales variables dépendantes ont été retenues, ces variables sont:

1. La tenue matelas (TM).
2. Le temps d'acquisition 1-2-3 (TA).
3. La rétention (RET).
4. L'absorption totale (AT).
5. L'absorption 10 pouces (ABS10).
6. La défibrillation de l'ouate ou taux acceptables (%ACC).

La raison pour avoir choisi seulement six variables dépendantes s'explique de la même façon que les choix faits avec les variables indépendantes. En fait, il faut considérer les variables les plus importantes et il faut aussi considérer le nombre de tests à faire sur machine.

3.3 DÉTERMINATION DU PLAN EXPÉRIMENTAL À PRENDRE

Cette étape est cruciale pour la bonne généralisation des calculs du RDN. Pour choisir le plan d'expérience à prendre, une hypothèse de départ a été émise et le choix du plan expérimental s'est fait en fonction de cette hypothèse de départ ainsi que la restriction qui était imposée par la compagnie.

- Ne connaissant pas les tendances « machine » entre deux points d'ajustement, il est supposé que les tendances entre ces deux points soient linéaires.
- À cause du temps « machine » disponible, un maximum de seize essais doit être effectué.

Pour justifier la généralisation des calculs selon les deux points mentionnés ci-haut, on doit prendre en considération que pour un même critère d'arrêt, un plan ne possédant que quelques expériences et un plan possédant plusieurs expériences, les résultats différeront sensiblement. L'approximation de la courbe entre les points pour un plan ne possédant que quelques expériences est plus difficile à faire, par contre un plan possédant plusieurs expériences est plus coûteux mais aussi plus précis. Il faut donc essayer de trouver le meilleur des deux mondes parmi ces choix. Dans cette étude, le

coût de la cueillette des données et les disponibilités « machine » géraient le choix du plan expérimental.

Pour cette recherche, considérant les conditions vues plus haut, le plan factoriel fractionné est, à première vue, le choix le plus logique. Les caractéristiques de ce plan sont les suivantes [2]:

<u>Factoriel fractionné</u>
Nombre de variables indépendantes considérées : 6 à 8
Nombre d'expériences à effectuer : 16
Nombre d'échantillons nécessaires : ≥ 3
Degré de résolution du plan (R) : 4
Niveau de confiance sur la variance : 95%
Niveau de confiance sur la moyenne : 99.99%

TABLEAU 3.2 : CARACTÉRISTIQUES DU FACTORIEL FRACTIONNÉ

Dans le Tableau 3.2, il est question du degré de résolution pour le plan expérimental. Selon [2], la résolution (R) d'un design expérimental peut se définir comme le type de représentation des différents éléments alliés lors du montage de ce dernier. La résolution R_{IV} du design expérimental ne fait pas l'alliance des principales interactions avec celles à deux voies, par contre il est permis de faire des alliances entre interactions à deux voies. Les designs de résolution R_{IV} sont utilisés principalement pour construire des équations de prédictions quand les ressources sont limitées pour des types à résolution R_V . Des connaissances préliminaires devront être utilisées pour déterminer quels effets d'alliances iront à l'intérieur de la future équation de prédiction.

Par rapport à ce qui a été dit au précédent paragraphe, pour cette présente recherche, il faut maintenant monter une matrice codée pour les différents essais à faire sur machine. Cette matrice, au Tableau 3.3, montre comment les différents facteurs à l'étude sont organisés au point de vue des alliances pour optimiser les effets d'interactions sur les différentes variables alliées.

Sur ce même Tableau 3.3 il est aussi possible de voir l'organisation des alliances des facteurs indépendants A à G. Le Tableau 3.4, de son côté, montre plus en détail quelle est la description de chaque facteur avec son unité correspondante et ses valeurs de niveau haut et bas.

Sur le Tableau 3.3, il est possible de voir pour les variables E, F et G les alliances suivantes: $E=ABC$, $F=BCD$ et $G=ABD$. Ce type d'alliance est typique à ce qui est donnée dans [2]. À cause du type de résolution de design expérimental (R_{IV}), le fait de vouloir explorer de nouvelles variables principales, soit E, F et G, l'alliance des ces dernières devait se faire avec des interactions à trois voies. Aussi, dans [2], il est dit que pour avoir une étude plus réussie sur une nouvelle variable à effet principal, il fallait insérer cette dernière à la place d'une interaction à trois voies ne possédant que peu d'interactions entre ses différents facteurs. Le chercheur s'est arrangé pour placer ses variables en fonction des alliances indiquées au Tableau 3.3. Par exemple, le

chercheur s'est arrangé pour placer l'ordre des variables A, B et C de telle sorte que ces dernières ne devraient pas avoir beaucoup d'interactions entre elles. La variable E dans son étude ne devrait pas refléter les interactions possibles de A, B et C; il est, dans ce cas, très peu probable que si la variable E possède un effet important sur une variable dépendante, que cet effet provienne des variables alliées ABC. La même philosophie s'appliquera aussi pour les variables F et G.

Bien sûr, tant que les expériences n'ont pas été menées il est difficile de juger le niveau d'interactions entre les différentes variables trois voies. C'est à ce moment que l'expertise des gens « machine » et aussi le gros bon sens fait son œuvre.

ESSAI	FACTEURS						
	A	B	C	D	E= ABC	F=BCD	G=ABD
1	+	+	+	+	+	+	+
2	+	+	+	-	+	-	-
3	+	+	-	+	-	-	+
4	+	+	-	-	-	+	-
5	+	-	+	+	-	-	-
6	+	-	+	-	-	+	+
7	+	-	-	+	+	+	-
8	+	-	-	-	+	-	+
9	-	+	+	+	-	+	-
10	-	+	+	-	-	-	+
11	-	+	-	+	+	-	-
12	-	+	-	-	+	+	+
13	-	-	+	+	+	-	+
14	-	-	+	-	+	+	-
15	-	-	-	+	-	+	+
16	-	-	-	-	-	-	-

TABLEAU 3.3 : MATRICE CODÉE DES ESSAIS.

Description de la variable	Unité	Niveau haut	Niveau bas
A. Distance de la calandre de gaufrage	po	0.050	0.025
B. Profondeur du S.A. (position du tube)	mm	48	40
C. Pression à la brosse égalisatrice (zone A)	po H ₂ O	25	15
D. Nombre de pâtes au marteau	Nombre	3	2
E. Distance entre breaker bar et les lames du broyeur	po	épaisseur pâte + 0.040	épaisseur pâte + 0.015
F. Cadence de production	coups/min	160	100
G. Distance de la brosse égalisatrice par rapport au tambour de formation	mm	5	0

TABLEAU 3.4: DESCRIPTION DES VARIABLES INDÉPENDANTES.

3.4 CONDUITE DES EXPÉRIENCES ET ENREGISTREMENT DES DONNÉES

Les essais « machine » ont été menés pendant la période située entre Noël et le Jour de l'An 2000. La machine Palmer se trouvait arrêtée pour la semaine complète. Le temps était donc bon pour effectuer la série d'expériences d'un seul trait. Les avantages de faire la série d'essais d'un seul trait étaient d'éviter toutes variations de résultats causées par le changement des poches de super absorbant aussi, il était possible d'éviter de construire des blocs d'essais à effets confondus. Enfin, il était possible, à partir des variables indépendantes suggérées par les employés, de rectifier une seule fois certaines variables considérées non importantes mais présentes. Par exemple, il avait été suggéré que les pochettes de formation sales puissent avoir une influence sur telle ou telle variable qualitative. Donc, au tout début des expériences et pour la seule fois, les pochettes ont été nettoyées, il a donc été possible de se retrouver dans une situation dite standard.

L'ordre dans lequel la série d'expériences a été faite est, on pourrait dire, à demi aléatoire. Il a été déterminé que trois variables indépendantes seraient probablement plus longues à ajuster. De ce fait, quatre groupes de quatre expériences ont été formés en fonction de ces trois variables. Parmi chacun des quatre groupes, l'ordre dans lequel les expériences ont été faites fut de façon aléatoire. Nous avons donc pu, d'une certaine façon couper un peu sur le temps « machine » prévu pour les expériences. Voici l'ordre des essais qui ont été effectués.

Ordre des essais: (En fonction des variables D, E et B)

1^e série : 1,11,7,13

2^e série : 6,16,4,10

3^e série : 3,9,5,15

4^e série : 8,14,12,2

Nombre d'échantillons par essai : quatre.

La méthode d'échantillonnage aléatoire revêt une certaine importance au niveau statistique. Il est dit que pour une certaine population contenant « N » éléments et un échantillon « n » de ce groupe pouvant être sélectionné, alors chacun des $\frac{N!}{(N-n)!n!}$ possibles échantillons devront avoir une chance égale d'être choisi. C'est la procédure employée appelée échantillonnage aléatoire [2].

Pour chaque essai effectué, on voudra avoir une moyenne sur les quatre valeurs échantillonnées et ceci pour toutes les variables dépendantes considérées. Par conséquent, il devient possible de vérifier statistiquement la validité des mesures et du lot produit.

Suite à la série de tests menés sur la machine Palmer, voici au Tableau 3.5 un résumé des résultats obtenus pour chaque série d'essais avec les calculs des écarts types ainsi que le pourcentage d'erreur reliée aux quatre valeurs échantillonnées. La

feuille complète des résultats obtenus se trouvera à l'annexe 1, situé à la fin du document. Une analyse plus exhaustive des résultats sera faite dans une section subséquente.

Il est important de noter que pour chaque ajustement fait sur la machine lors des essais, les résultats des calculs du RDN seront à l'image de la précision de ces derniers ajustements. Donc, pour un RDN la célèbre citation « garbage in, garbage out » s'applique encore très bien.

ESSAI	1	2	3	4	5	6	7	8	9	10
Moyenne TM	289,53	609,38	240,90	381,35	365,45	199,65	434,65	305,30	599,80	342,28
Ecart-type	17,63	87,21	19,66	60,68	70,29	41,70	61,48	63,24	98,67	50,67
%Erreur	3,32	16,42	3,70	11,43	13,24	7,85	11,58	11,91	18,58	9,54
Moyenne TA	133,19	104,75	116,67	112,88	106,77	115,88	95,43	128,49	112,43	146,34
Ecart-type	4,70	9,76	6,03	13,17	2,63	6,10	2,71	4,86	5,95	10,98
%Erreur	8,73	18,13	11,20	24,47	4,89	11,32	5,04	9,03	11,05	20,40
Moyenne RET	250,93	230,13	227,90	231,02	221,24	236,33	250,49	224,57	245,60	233,50
Ecart-type	2,53	9,82	15,59	3,22	12,37	11,37	7,87	17,66	3,49	13,70
%Erreur	4,53	17,57	27,89	5,76	22,13	20,34	14,07	31,59	6,24	24,51
Moyenne AT	1514,75	1416,75	1437,50	1381,75	1402,75	1382,25	1465,00	1467,50	1434,50	1448,75
Ecart-type	31,80	12,84	26,44	29,12	33,97	24,82	49,16	75,69	29,31	29,02
%Erreur	11,67	4,71	9,70	10,69	12,47	9,11	18,04	27,78	10,76	10,65
Moyenne ABS10	567,75	620,75	546,50	617,75	585,00	525,25	600,75	552,25	593,00	521,25
Ecart-type	18,84	4,65	14,11	19,26	24,78	15,76	16,07	22,02	27,68	25,13
%Erreur	12,04	2,97	9,02	12,31	15,83	10,07	10,27	14,07	17,68	16,06
Moyenne %ACC	83,89	79,20	79,76	87,55	83,54	85,17	83,27	83,02	87,32	87,66
Ecart-type	2,45	1,60	5,49	0,79	1,35	1,35	3,59	3,23	1,71	1,52
%Erreur	27,22	17,78	61,00	8,78	15,00	15,03	39,89	35,87	18,99	16,88

ESSAI	11	12	13	14	15	16	17	18	19	Moyenne
Moyenne TM		227,18	715,63	348,90	396,40		535,60	184,63	469,32	14,30%
Ecart type		54,04	224,34	74,98	50,08		123,14	65,30	128,10	
%Erreur		10,18	42,25	14,12	9,43		23,19	12,30	24,12	
Moyenne TA	120,50	124,12	149,25	127,38	126,98	103,02	99,79	106,91	103,05	10,93%
Ecart-type	8,38	5,37	2,14	5,28	7,78	8,15	3,08	7,10	2,75	
%Erreur	15,56	9,99	3,97	9,81	14,45	15,14	5,73	13,20	5,11	
Moyenne RET	240,15	236,40	231,60	254,83	277,13	273,68	264,60	267,73	280,20	22,77%
Ecart-type	19,36	9,42	23,66	10,02	18,57	23,69	18,00	13,47	9,02	
%Erreur	34,63	16,86	42,33	17,93	33,22	42,39	32,20	24,09	16,14	
Moyenne AT	1270,50	1413,50	1411,50	1380,50	1482,50	1539,50	1407,25	1451,75	1543,00	13,06%
Ecart-type	23,30	14,39	39,77	44,29	37,60	92,42	20,69	23,67	31,25	
%Erreur	8,55	5,28	14,59	16,25	13,80	33,92	7,59	8,69	11,47	
Moyenne ABS10	511,25	531,00	506,00	556,25	528,25	634,75	600,50	555,75	662,50	11,64%
Ecart-type	18,46	34,12	7,70	3,86	10,60	32,12	31,97	14,80	11,09	
%Erreur	11,80	21,80	4,92	2,47	6,77	20,52	20,43	9,45	7,09	
Moyenne %ACC	83,87	84,45	83,36	84,50	82,40	86,12	83,23	88,18	82,39	24,08%
Ecart-type	2,15	2,09	2,19	2,31	2,12	1,18	1,59	1,14	2,69	
%Erreur	23,87	23,23	24,37	25,61	23,52	13,12	17,68	12,67	29,89	

Moyenne générale:	16,13%
-------------------	--------

TABLEAU 3.5: RÉSUMÉ DES RÉSULTATS OBTENUS.

3.5 MÉTHODOLOGIE SUR L'ANALYSE DE VARIABILITÉ ET SENSIBILITÉ PAR PARETO

Avant de commencer à faire une analyse de sensibilité par Pareto, il faut s'assurer d'avoir les données des expériences « machine » sous la main. Le Tableau 3.6 donne toutes les informations à propos des données recueillies. C'est donc à partir de ce tableau que sera fait l'analyse.

# Essai	Discal	Profsa	Pression	Nbpate	Disbreak	Prodrate	Disbross	TM	TA	RET	AT	ABS10	%ACC
1	0,05	48	25	3	0,04	160	5	289,525	133,19	250,925	1514,75	567,75	83,887
2	0,05	48	25	2	0,04	100	0	609,375	104,747	230,125	1416,75	620,75	79,2
3	0,05	48	15	3	0,015	100	5	240,9	116,667	227,9	1437,5	546,5	79,76
4	0,05	48	15	2	0,015	160	0	381,35	112,875	231,017	1381,75	617,75	87,552
5	0,05	40	25	3	0,015	100	0	365,45	106,767	221,237	1402,75	585	83,537
6	0,05	40	25	2	0,015	160	5	199,65	115,882	236,325	1382,25	525,25	85,172
7	0,05	40	15	3	0,04	160	0	434,65	95,425	250,49	1465	600,75	83,272
8	0,05	40	15	2	0,04	100	5	305,3	128,485	224,57	1467,5	552,25	83,022
9	0,025	48	25	3	0,015	160	0	599,8	112,432	245,597	1434,5	593	87,32
10	0,025	48	25	2	0,015	100	5	342,275	146,34	233,502	1448,75	521,25	87,657
11	0,025	48	15	3	0,04	100	0		120,5	240,152	1270,5	511,25	83,87
12	0,025	48	15	2	0,04	160	5	227,175	124,12	236,397	1413,5	531	84,44
13	0,025	40	25	3	0,04	100	5	715,625	149,25	231,597	1411,5	506	83,36
14	0,025	40	25	2	0,04	160	0	348,9	127,377	254,825	1380,5	556,25	84,502
15	0,025	40	15	3	0,015	160	5	396,4	126,982	277,125	1482,5	528,25	82,395
16	0,025	40	15	2	0,015	100	0		103,017	273,675	1539,5	634,75	86,117
17	0,025	40	25	3	0,04	160	0	535,6	99,8	264,6	1407,3	600,5	83,2
18	0,05	48	25	3	0,04	160	5	184,6	106,9	267,4	1451,8	555,8	88,2

TABLEAU 3.6: DONNÉES DE DÉPART POUR PARETO.

La notion de valeur haute et basse sur les variables indépendantes prendra tout son sens ici lors de cette analyse. L'analyse de sensibilité par Pareto considère, selon les changements d'états, les tendances et les influences entre des valeurs hautes et basses seulement. Cette analyse est donc faite sur mesure pour des variables à deux niveaux. À noter aussi les carreaux vides pour les essais 11 et 16, ce sont deux données qui ont été rayées à cause de leurs trop grosses différences de valeur (3202 et 6736) avec les autres données. Une explication plus poussée sur ces deux données sera développée dans le chapitre subséquent.

À partir des données du Tableau 3.6 haut, il faut maintenant créer un autre tableau. Ce tableau est celui des calculs des effets. Il existe un tableau des calculs des effets pour chaque variable indépendante. Un calcul de différence de valeur basé sur la moyenne des valeurs pour chaque niveau est fait sur chaque variable dépendante entre sa valeur haute et basse. Le Tableau 3.7 donne un aperçu de ce travail pour la variable indépendante « profsa ».

Calculs des effets						
profsa	tm	ta	ret	at	abs10	acc
40	412,70	117,00	248,27	1437,64	565,44	83,84
48	359,38	119,75	240,34	1418,87	562,78	84,65
DIFF	-53,32	2,75	-7,94	-18,78	-2,66	0,81
1/2 effet	26,66	1,38	3,97	9,39	1,33	0,41

TABLEAU 3.7: CALCULS DES EFFETS.

La rangée des différences (DIFF) donne deux informations. D'abord, le signe + ou – indique la tendance de l'effet par rapport à la variable indépendante. C'est une indication plus visuelle pour savoir quelles variables possèdent l'effet dans un même sens. Ensuite, il y a la valeur propre qui indique l'amplitude de l'effet. Par exemple au Tableau 3.7, il est possible de voir que la variable de la tenue matelas semble posséder la plus grande sensibilité ou effet par rapport à la profondeur de super absorbant « profsa ». De même le pourcentage des acceptables « acc » donne l'impression de n'avoir aucune sensibilité ou presque, par rapport à la profondeur du super absorbant. Il

faut faire attention ici car aucune des valeurs du précédent tableau n'indique quoi que ce soit pour l'instant. Il faut considérer tous les tableaux des calculs des effets dans leur ensemble pour pouvoir tirer des conclusions.

Une fois tous les tableaux d'effets calculés, il est possible de tracer un graphique des effets en fonction d'une seule variable dépendante. La Figure 3.1 montre de façon visuelle les résultats obtenus par rapport aux sept tableaux des calculs d'effets.




FIGURE 3.1: GRAPHE DES EFFETS SUR LE TEMPS D'ACQUISITION.

À partir d'ici, il est possible de commencer à tirer des conclusions sur les effets des variables indépendantes en fonction du temps d'acquisition, dans ce cas présent, par rapport à la variable du temps d'acquisition « TA ». Ce graphique donne à coup sûr les premières bonnes indications des tendances. Tous les autres graphiques de ce genre seront situés à l'annexe cinq à la fin du document.

Pour continuer avec les résultats du Tableau 3.7, la rangée du « $\frac{1}{2}$ effet » permet de pouvoir tracer le graphe de Pareto correspondant. Dans la même optique que le graphe des effets, il faudra attendre d'avoir tous les graphes des effets en main pour pouvoir tracer un graphe de Pareto et tirer des conclusions. Tout comme le graphe des effets, le graphe de Pareto est montré par rapport à une seule variable dépendante et est construit en fonction des différentes variables indépendantes. La Figure 3.2 montre un exemple de ce qu'est un graphe de Pareto.

Telle que prévue par le graphe des effets à la Figure 3.1, la distance de la brosse égalisatrice possède le plus grand effet sur la variable du temps d'acquisition « TA ».

Voilà qui termine cette analyse de sensibilité par Pareto. Les différents graphes de Pareto seront aussi mis à l'annexe six, pour fin de consultation. L'analyse des résultats par rapport à cette étude sera fait dans le chapitre suivant.




FIGURE 3.2: GRAPHE DE PARETO POUR LE TEMPS D'ACQUISITION.

Maintenant que nous connaissons en général les différents effets sur chaque variable dépendante, il serait intéressant de valider ces réponses avec le RDN. Il ne serait pas surprenant que certains sens de tendances changent ou que l'amplitude des effets pour certaines variables dépendantes change aussi.

3.6 MÉTHODOLOGIE D'ANALYSE DES RÉSULTATS PAR RDN

Pour réussir à faire une analyse complète des résultats par RDN, deux options s'offraient au chercheur : construire par programmation un logiciel de RDN ou utiliser un logiciel déjà tout fait; la deuxième option fut choisie. Le logiciel « Cadsim Plus Papdyn » de la compagnie « Aurel System inc. » fut le logiciel employé. « Cadsim » est encore un logiciel de version bêta en ce qui concerne le module des RDN, par conséquent il est fragile en fonctionnement et pas très convivial. C'est une raison qui fait croire qu'il serait bon de valider ces résultats avec ceux trouvés lors de l'analyse par Pareto.

3.6.1 ARCHITECTURE ET ENTRAÎNEMENT DES RDN

Il existe plusieurs variables pouvant faire fonctionner un RDN. Pour ce qui est de la partie « entraînement » du réseau de neurones on retrouve:

- le nombre de niveaux intermédiaires.
- le nombre d'éléments par niveau intermédiaire.
- le pourcentage associé au critère d'arrêt.
- le taux d'apprentissage.
- le momentum.

- le type de fonction de transfert (sigmoïde et tangente hyperbolique).
- le nombre d'itérations à l'entraînement.

La première chose à faire lors du cheminement pour l'obtention des résultats par RDN, est d'abord de faire un entraînement des variables qui sont déjà connues, soit les valeurs trouvées lors des essais « machine ». Avant de faire l'entraînement, il faut scruter toutes les variables d'entraînement et s'assurer que chacune d'entre elles ne possèdent pas une valeur sortant exagérément de la moyenne de l'ensemble. Si c'est le cas, il faut alors la rayer de l'entraînement pour éviter que cette dernière ne vienne affaiblir le pouvoir de généralisation du RDN.

Dans le cas de notre recherche, l'entraînement des variables dépendantes doit débuter sans trop considérer l'architecture du réseau soit le taux d'apprentissage ou le momentum. Ce qui importe au départ est de trouver la bonne valeur de critère d'arrêt d'entraînement en fonction des valeurs trouvées sur machine. Comme il a été vu précédemment au Tableau 3.5, pour chaque essai mené, une valeur moyenne d'erreur reliée à l'écart type est calculée en fonction des quatre échantillons recueillis pour chaque essai. Une moyenne générale des erreurs reliées à l'écart type a donc été calculée pour chaque variable dépendante considérant tous les essais. C'est donc à partir de cette valeur qu'il faut ajuster le critère d'arrêt pour faire l'entraînement des variables. Par exemple la variable dépendante « TM » possède en moyenne une erreur reliée à l'écart type sur ses valeurs recueillies de 14.3%. Il ne sert donc à rien d'entraîner le RDN pour des précisions de 3% ou 4% si la moyenne des erreurs reliées à l'écart type est de 14.3%; les réponses provenant du RDN ne refléteront pas la réalité. Pour réussir à avoir des réponses réalistes provenant du RDN il faut s'adapter à la qualité des réponses que nous avons obtenues sur machine et amener la précision d'entraînement près des valeurs trouvées.

3.6.2 MÉTHODOLOGIE D'ENTRAÎNEMENT UTILISÉE LORS DE LA RECHERCHE

L'entraînement des variables est très important dans l'établissement d'un réseau de neurones et il est vraiment la base pour de bons résultats lors des démarches futures. Lors de notre recherche, les entraînements s'effectuent à l'intérieur d'un module programmé en Borland C++. Ce module est physiquement séparé du logiciel de RDN et géré par Cadsim. La raison est simplement due au caractère pratique de la chose.

Avec l'aspect d'entraînement vient la notion de généralisation du réseau. La généralisation est le qualificatif employé pour désigner un réseau de neurones qui a bien appris les différentes données d'entraînement qui lui ont été envoyées et si son domaine appris reproduit bien la réalité [3]. Un RDN peut trop ou pas assez généraliser le domaine à l'étude. Dans les deux cas ce sont des situations à éviter.

La généralisation est influencée par trois facteurs [3] :

- La grandeur et l'efficacité des séries d'entraînements
- L'architecture du réseau
- La complexité physique du problème

Pour illustrer ce qu'est la généralisation d'un réseau, il serait possible de faire une comparaison avec une descente à ski alpin, le slalom tout particulièrement. Pour arriver au bas de la pente selon un temps optimum, il faut qu'entre chaque porte le skieur prenne le bon tracé en fonction de la porte suivante. Des virages trop serrés entre chaque porte ralentissent la descente tandis que des virages trop larges font aussi perdre du temps pour rien. Il faut donc trouver l'optimum. La généralisation d'un RDN se situe dans la même optique. De cette description analogique, les portes pourraient être vues comme étant les points de la courbe à atteindre tandis que le parcours fait par le skieur serait vu comme étant l'approximation faite par le réseau de neurones.

Lors de cette étude il y a eu dix-huit expériences « machine » effectuées donc dix-huit données pour chaque variable indépendante. Une exception, « TM », où deux variables sont rayées. La méthodologie employée pour l'entraînement est simple:

1. Avec dix-huit données, il faut bâtir trois séries d'expériences pour chaque variable dépendante. Sur chaque série d'expériences on retire quatre données du groupe et on les garde comme données tests. Les quatorze autres données servent pour l'entraînement du RDN. La théorie suggère toujours de garder environ 15% à 20% des données d'un groupe d'entraînements pour des validations. C'est donc ce qui a été fait.
2. Une fois les trois séries d'expériences préparées, une moyenne des précisions est calculée. Cette moyenne doit correspondre le plus près possible au nombre de l'erreur reliée à l'écart type donné (voir Tableau 3.5) et cela pour chaque variable dépendante considérée.
3. En faisant varier la variable du pourcentage d'erreur durant l'entraînement, on peut s'apercevoir que certaines valeurs d'erreur sont plus propices que d'autres et donnent des résultats plus intéressants. Quand ces pourcentages sont trouvés, il est ensuite possible de jouer avec la topologie du réseau. En jouant avec le nombre d'éléments par niveau intermédiaire, il est possible de raffiner davantage les résultats trouvés.

Un exemple de résultats obtenus par cette méthodologie est montré au Tableau 3.8, partie de gauche. La série complète des autres tableaux concernant les autres variables dépendantes est mise aux annexes deux et trois situées à la fin du document pour fin de consultation.

Pour valider que les calculs par RDN donnent des résultats conformes à l'entraînement effectué, les mêmes séries d'entraînements sont calculées au RDN (la partie gérée par le logiciel Cadsim). Le Tableau 3.8 montre aussi un exemple de ce type de résultats.

BORLAND			CADSIM		
TA (14%) H=3,0			Entraînement vs ZIG	TA (sec)	Précision (%)
	# Essai	Précision (%)			
1re série	1	33,33	1re série	vs 1	115,25
	4	10,25		vs 4	107,36
	10	33,12		vs 10	128,51
	16	35,33		vs 16	122,03
	Moyenne	28,01		Moyenne	28,01
2e série	2	8,23	2e série	vs 2	109,18
	6	0,69		vs 6	116,25
	9	1,907		vs 9	111,4
	14	34,4		vs 14	108,86
	Moyenne	11,31		Moyenne	11,31
3e série	3	4,84	3e série	vs 3	114,06
	8	14,88		vs 8	120,48
	12	4,79		vs 12	126,7
	17	38,18		vs 17	120,35
	Moyenne	15,67		Moyenne	15,67
MOYENNE:		18,33	MOYENNE:		18,33

TABLEAU 3.8: ENTRAÎNEMENTS DES DONNÉES.

Maintenant que l'étape d'entraînement est complétée, il est possible de penser que le RDN sait bien reconnaître le domaine de chaque variable dépendante. De ce fait, il est maintenant possible de déterminer avec ce même RDN quelles seront les variables indépendantes ayant les plus grandes influences sur les variables dépendantes de façon globale.

3.6.3 ANALYSE DE SENSIBILITÉ PAR RDN

L'analyse de sensibilité par réseau de neurones est une occasion de valider les résultats obtenus de l'analyse de sensibilité de Pareto.

L'avantage du RDN par rapport à l'analyse de sensibilité faite auparavant est que le RDN prend en considération plusieurs variables dépendantes en même temps lors de ses calculs, ce qui n'est pas le cas de l'analyse par Pareto. Ce faisant, il peut arriver que les résultats obtenus lors de l'étude des effets soient quelque peu différents que ceux trouvés par Pareto.

Comme pour la précédente analyse par Pareto, un tableau pour classifier les effets des variables indépendantes en fonction d'une variable dépendante unique est construit. Le Tableau 3.9 montre un exemple de ce type d'analyse.

123,233 42,40%	118,503 10,85%	106,564 27,40%					80,65%
DISBROSS	DISCAL	PRODRATE	PRESSION	NBPATE	PROFSA	DISBREAK	TA
0	0,05	175	15	3	48	0,105	98,13
	▲	▲		▲	▲		▲
▼			▼			▼	
5	0,025	100	25	2	40	0,181	141,71

TABLEAU 3.9: ANALYSE DES EFFETS PAR RDN SUR LE TEMPS D'ACQUISITION.

L'explication de ce tableau est simple. Les sept premières colonnes sont les colonnes des variables indépendantes. Les variables de gauche à droite sont placées selon l'ordre des plus influentes aux moins influentes par rapport à la variable dépendante du temps d'acquisition « TA ». Aussi, quand on regarde le tableau de bas en haut, les données sont toujours placées en fonction du pire ajustement « machine » vers le meilleur ajustement « machine ». Donc pour ce tableau, la première ligne du haut indique les meilleurs ajustements « machine » tandis que la ligne du bas montre les pires. Ces ajustements ne sont valides que pour la variable « TA » seulement.

Pour les colonnes des variables indépendantes, les flèches indiquent le déplacement de l'ajustement bas vers l'ajustement haut. Pour la variable dépendante, la flèche est toujours placée du bas vers le haut pour montrer la direction du bon ajustement. C'est une façon plus visuelle de voir dans l'ensemble quelles sont les tendances des variables indépendantes.

Initialement, quand l'analyse des effets s'effectue avec le RDN, l'organisation du tableau est faite en fonction des résultats trouvés avec l'analyse de sensibilité de Pareto. Les variables indépendantes sont mises dans le même ordre que sur le graphe de Pareto et les tendances, dans le même sens que sur le graphe des effets.

Alors, à partir de la série d'ajustements considérée la pire, les variables indépendantes changent une par une vers la valeur d'ajustements considérée la meilleure. L'étude consiste à analyser quelles sont les valeurs qui ont le plus grand effet sur le changement de la variable dépendante à l'étude. Quand une première valeur est trouvée, on la garde dans son état préférentiel et on va voir quelle est la prochaine variable à avoir le plus grand effet. Cette analyse se poursuit jusqu'à ce qu'on ait atteint au moins 80% de la plage théorique possible de la variable dépendante. Cette plage théorique est déterminée au préalable en calculant selon la meilleure série d'ajustements et la pire série d'ajustements.

Le dernier paragraphe amène à parler des deux séries de chiffres situées au-dessus du Tableau 3.9. Cette série de chiffres indique comment la progression des

résultats sur la variable dépendante s'effectue. En partant avec une série d'ajustements considéré comme étant la pire pour la variable « TA » et en changeant la variable « disbross » de la valeur cinq vers la valeur zéro, le résultat de la variable « TA » passe de 141.71 à 137.233 pour une augmentation de 42.4% de la valeur. Les chiffres de l'autre colonne soit « discal » montrent que d'avoir monté cette variable de 0.025 à 0.05, à fait passer « TA » de 123.233 à 118.503 pour une augmentation supplémentaire de 10.85%. La valeur du pourcentage n'est pas cumulative mais est distincte pour chaque déplacement de variable indépendante. Le chiffre situé au-dessus de la variable « TA » dans le Tableau 3.9 indique le pourcentage de la plage parcourue par les variables ayant changé d'état. Pour tous les autres tableaux étudiés, la plage atteinte se situe toujours près de 80%. Il a été vu que les variables indépendantes des derniers rangs n'avaient, de toute façon, presque plus d'effets sur la variable dépendante. Aussi lors du montage du tableau final comprenant l'analyse de toutes les variables dépendantes en fonction des variables indépendantes, il est plus facile d'analyser le tout pour trouver les valeurs de mise en route optimales.

Toujours au Tableau 3.9, les variables indépendantes sont placées par ordre décroissant soit la variable avec le plus d'influence vers la variable avec le moins d'influence. Le lecteur attentionné verra que le pourcentage situé au-dessus du tableau ne respecte pas l'ordre tel que décrit, c'est vrai. Ce phénomène sera décrit au chapitre suivant lors de l'analyse des résultats.

Pour ce qui est des autres tableaux des effets calculés par RDN, ces derniers se retrouvent placés à l'annexe sept pour fin de consultation. L'analyse des résultats se fera dans le chapitre suivant.

3.7 CRÉATION DU TABLEAU FINAL

Maintenant que tous les effets de toutes les variables dépendantes sont connus et bien classifiés, il ne reste qu'à produire un tableau récapitulatif de tous les tableaux et de tirer des conclusions. Le Tableau 3.10 montre les résultats obtenus à partir des différents autres tableaux des effets.

Le Tableau 3.10 se veut le résultat ultime de la présente recherche, voici donc ce tableau.

	TM	TA	RET**	AT	ABS10	ACC
DISCAL	2 DOWN	2 UP	2 DOWN	2 UP	2 UP	3 DOWN
PROFSA			3 DOWN			
PRESSION	3 UP					2 DOWN
NBPATE	4 UP		4 UP	3 UP		4 UP
DISBREAK					3 DOWN	
PRODRATE		3 UP	1 UP			1 UP
DISBROSS	1 DOWN	1 DOWN		1 UP	1 DOWN	

TABLEAU 3.10: SOMMAIRE DES RÉSULTAS OBTENUS.

Le fonctionnement de ce tableau est aussi très simple. Pour chaque variable dépendante, selon le graphe des effets calculés par RDN, la variable la plus influente

possède le numéro un et plus on monte avec le nombre, moins elle possède d'influence.

Enfin, la mention « UP » ou « DOWN » indique la tendance de la variable indépendante. C'est encore une façon plus visuelle de voir comment se comporte chaque variable indépendante. À partir de ce tableau on peut tirer énormément d'informations. Ces informations seront données dans le chapitre quatre qui suit.

CHAPITRE IV

ANALYSE DES RÉSULTATS (VARIABLES DÉPENDANTES)

4.1 RETOUR SUR LES RÉSULTATS D'EXPÉRIENCES « MACHINE »

La présente analyse a trait aux résultats de données recueillies sur la machine Palmer. Cette feuille de résultats est la première et est située à l'annexe un; elle s'intitule « Feuille de résultats d'essais Palmer ».

La première action à faire en regardant cette feuille de résultats est ce qu'on appelle le « eye ball analysis ». Ce type d'analyse consiste à jeter un regard sur chacun des résultats et pour chaque variable dépendante, déterminer quelle valeur pourrait sortir de l'ordinaire par rapport au groupe. Pour ce qui est de nos résultats, il a été possible de trouver, pour la variable dépendante de la tenue matelas « TM », deux valeurs sortant exagérément du reste du groupe. Ces deux valeurs se trouvent aux essais 11 et 16.

Ces erreurs peuvent être interprétées comme des erreurs de manipulation au laboratoire. Elles peuvent aussi être à l'origine d'une valeur de mise en route pas très conventionnelle pour la machine, qui sait... Une chose est certaine, ces valeurs doivent être écartées des calculs qui suivent car ces dernières ont un impact direct sur le degré de généralisation du domaine à étudier. Il n'y a déjà pas beaucoup de variables à l'étude présentement, il ne faudrait pas commencer à faire diluer le pouvoir de généralisation du RDN.

À la suite de cette mise à l'écart de ces deux variables, il est maintenant possible de calculer à partir de chaque valeur moyenne de chaque essai, une valeur d'écart type pour chaque variable dépendante, l'erreur reliée au calcul de l'écart type (Voir Tableau 3.5 pour référence). En considérant maintenant pour chaque valeur d'essai sur chacune des variables dépendantes, la valeur la plus haute et la plus basse, celles-ci seront prises pour effectuer le calcul du pourcentage d'erreur sur l'écart type. Donc, pour chaque valeur d'essai de chacune des variables dépendantes, un pourcentage d'erreurs est calculé. La moyenne de ces pourcentages d'erreurs est ensuite calculée pour chaque variable dépendante. Le Tableau 4.1 montre un sommaire des ces calculs.

Selon ce même Tableau 4.1 et ses résultats, il est déjà possible de spéculer sur l'architecture du RDN qui sera utilisé. Le RDN doit donc comprendre trois modules de calculs pour le traitement des données.

Variable	Moyenne (%)
TM	14.30
TA	10.93
RET	22.77
AT	13.06
ABS10	11.64
%ACC	24.08

TABLEAU 4.1: ERREURS RELIÉES À L'ÉCART TYPE.

D'abord, un premier module de calculs pour la variable « TM » car cette dernière possédant sa série de données amputées, elle nécessite un traitement de calculs particuliers. Ensuite un autre module de calculs pour les variables « TA », « AT » et « ABS10 ». Ces trois variables possèdent une valeur moyenne d'erreurs reliées à l'écart type assez semblable, il est de bon usage alors de leur dédier un module de calculs particuliers. Finalement, pour les mêmes raisons que les trois variables précédentes, les variables « RET » et « %ACC » auront leur propre unité de calculs dédiés. La Figure 4.1 montre comment sont physiquement bâtis ces modules de calculs.

À partir des derniers résultats vus au Tableau 4.1 de la page précédente, il est possible de conclure que le RDN ne pourra pas être plus précis dans ses calculs que la moyenne des erreurs reliées à l'écart type trouvée lors de la cueillette des données sur machine. Si on veut demeurer réaliste dans les résultats de calculs avec le RDN, il faudra suivre cette voie sinon les résultats ne voudront rien dire. On voit bien là l'importance des données recueillies et chacune de leur valeur.

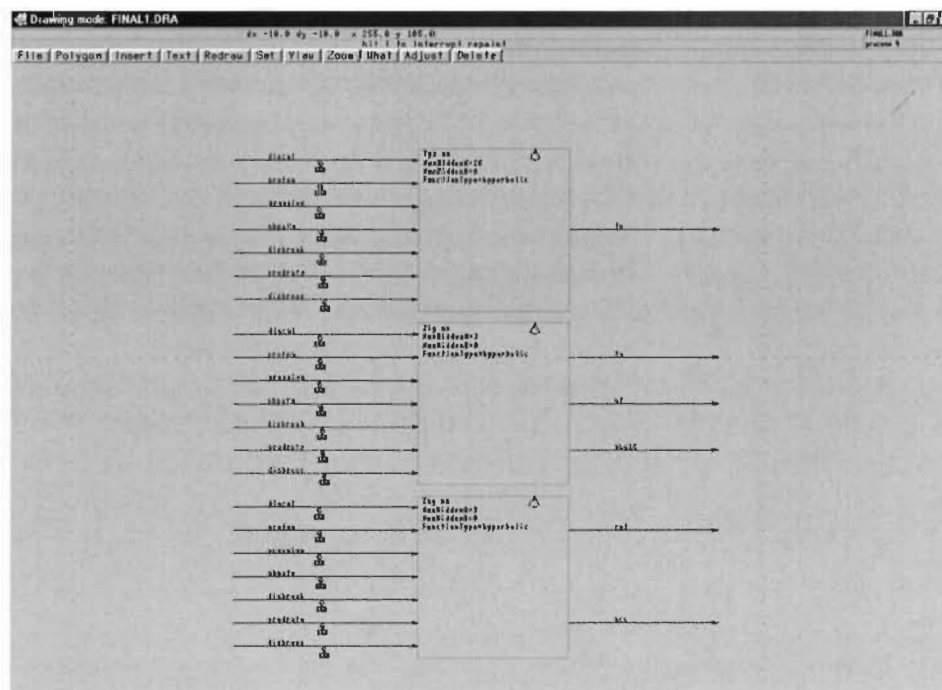


FIGURE 4.1: REPRÉSENTATION PHYSIQUE DES CALCULATEURS DU RDN.

Lors de la cueillette de données sur machine, les seize expériences de base définissant le factoriel fractionnée ont été menées. Pour réussir à faire des tests suivant l'entraînement avec le RDN, il fallait aussi récolter des données pour cet usage; le chercheur a cru bon d'effectuer deux autres tests « machine », ce fut les expériences dix-sept et dix-huit servant de variables tests.

Après avoir fait les premiers tests préliminaires avec le RDN, il était évident qu'il manquait des variables pour l'entraînement. La seule chance de réussir à avoir une autre série de données supplémentaires pour pas cher, était de faire analyser le produit qui sortait de la machine Palmer actuellement en production. Bien sûr, les valeurs de mise en route ne respectaient pas les niveaux « haut et bas » définis par le plan d'expérience mais au moins, il était possible de se servir de cette nouvelle série de données comme validation test et inclure les expériences dix-sept ou dix-huit dans l'entraînement. Cette nouvelle série de données un peu à part, se nomme donc l'essai dix-neuf. L'annexe un situé à la fin du document présente inclusivement tous les résultats de ces essais, soit de l'essai un à l'essai dix-neuf.

4.2 RÉSULTATS SUR LES ENTRAÎNEMENTS

La présente analyse portera sur l'étude des tableaux intitulés « Précisions des validations Cadsim » et « Précisions des entraînements Borland » situés aux annexes deux et trois.

Les résultats sur les entraînements montrent beaucoup de choses par rapport au domaine étudié sur chaque variable dépendante. Dans l'analyse de ces tableaux il est possible de voir deux tendances.

D'abord, il est possible de voir que la précision des entraînements pour un essai particulier peut être mauvaise, peu importe la variable dépendante rencontrée comme par exemple avec l'essai seize. Dans la majorité des cas, la précision se retrouve loin de l'objectif de précision visé. Rappelons que cet objectif est fixé par l'erreur reliée à l'écart type trouvée lors des essais « machine ». Si on se réfère au Tableau 3.5, on peut voir que les valeurs données par l'essai seize se situent toujours près des minimums ou maximums de l'étendue des données. La seule exception est pour la variable dépendante du pourcentage d'acceptables « %ACC », la donnée se situe près du milieu de l'étendue et comme par hasard la précision de l'entraînement est beaucoup plus près de la cible visée. Il y a donc une première conclusion à tirer de cette situation. La précision de calculs d'un RDN est de plus en plus mauvaise au fur et à mesure que l'on s'approche des limites du domaine à l'étude. Si une donnée située à l'extérieur du domaine étudié est à trouver, la crédibilité sur la précision de cette variable deviendra quasi nulle.

Enfin, une autre tendance qui est plutôt facile à remarquer est la précision des entraînements à l'intérieur d'une même série. Si on prend par exemple la deuxième série d'entraînements pour la variable dépendante « TA » située à l'annexe deux, on peut voir que les précisions varient 0.69% à 8.23% mais qu'une seule valeur prend

34.4% en précision. On pourrait penser que la plupart des données sont dans une même région et que la valeur 34.4% provient d'une valeur isolée par rapport au domaine. Ce n'est pas le cas. La Figure 4.2, plus bas montre que la série de données est relativement bien distribuée et que le domaine étudié n'est pas si difforme.




FIGURE 4.2: DISTRIBUTION DES VALEURS DE TA.

Ce qui peut expliquer ce phénomène est d'abord et avant tout la topologie du réseau. En faisant les entraînements avec seulement trois neurones au niveau intermédiaire, le réseau a tendance à faire ses approximations de façon plus linéaire entre chaque donnée. Un réseau avec dix ou quinze neurones intermédiaires aurait donné des approximations beaucoup moins linéaires et le phénomène aurait été moins perceptible. Jouer avec une topologie de réseau est un peu comme faire un ajustement de courbe entre des points. Pour notre variable « TA » la topologie qui minimisait l'erreur à l'entraînement et qui rencontrait l'objectif par rapport aux erreurs reliées à l'écart type était la topologie avec trois neurones intermédiaires.

On peut aussi constater que pour une variable dépendante, la moyenne de précision pour trois séries d'entraînements ne donne pas tout à fait la valeur exacte donnée par l'erreur reliée à l'écart type. Il faut se dire que si un nombre beaucoup plus important de séries d'entraînements avaient été faits, la moyenne aurait eu tendance à converger vers la valeur de l'erreur reliée à l'écart type.

Les essais choisis pour chaque série d'entraînements ont été faits de façon aléatoire dans le but d'éviter les provocations de tendances.

4.3 RÉSULTATS SUR LES ANALYSES DU RDN

La façon de fonctionner pour ce sous-chapitre est le suivant. Lors de cette analyse des résultats, chaque variable dépendante sera analysée en fonction de l'étude de sensibilité faite par Pareto ainsi que par le tableau des effets calculés par le RDN (voir Tableau 3.7). Chaque variable dépendante sera analysée, une après l'autre. Cette

façon de fonctionner permettra au lecteur d'aller chercher les informations plus facilement lors de consultations ultérieures.

Les figures complètes de l'analyse de sensibilité sont disponibles pour consultations aux annexes cinq et six. Pour les tableaux des effets calculés par RDN ces derniers sont inclus au début de chaque sous-chapitre correspondant à la variable à l'étude. Il est aussi possible de consulter les résultats en vue globale à l'annexe sept sous le titre « Tableaux des effets calculés par RDN ».

4.3.1 TENUE MATELAS (TM)

L'analyse de cette variable est probablement la plus difficile à faire parmi toutes les variables mises à l'étude. Par définition, la méthode d'analyse pour la tenue matelas a pour but de mesurer la force de résistance du matelas sur un produit fini.

Comme montré au Tableau 4.2, les principales variables dépendantes ayant un effet majeur sur « TM » sont la distance de la brosse égalisatrice « disbross », la distance de la calandre de gaufrage « discal », la pression d'aspiration à la zone « A » sur le tambour de formation « pression » et le nombre de pâtes utilisées « nbpâte ».

327,03 22,28%	423,61 27,11%	493,92 19,73%	547,264 14,97%				84,10%
DISBROSS	DISCAL	PRESSION	NBPATE	PRODRATE	PROFSA	DISBREAK	TM
0	0,025	25	3	100	40	0,181	603,93
		▲	▲			▲	▲
▼	▼			▼	▼		
5	0,05	15	2	175	48	0,105	247,63

TABLEAU 4.2 CALCULS DES EFFETS PAR RDN POUR TM.

À première vue, pour obtenir une tenue matelas optimale, il est logique de penser d'avoir de la part du procédé, un système de mélange des fibres le plus aléatoire possible pour que le produit final soit de résistance maximale. En fait, si théoriquement toutes les fibres sont placées selon un alignement parfait, aucune tenue du matelas n'est possible. Ce phénomène semble donc se retrouver au travers de la variable « disbross ». Bien qu'il soit évident qu'un mélange des fibres s'effectue lors de la défibrage des pâtes au broyeur à marteaux, les résultats provenant du RDN montrent qu'un mélange supplémentaire des fibres à la base du matelas est bénéfique.

L'autre avantage majeur de cette variable « disbross » peut venir du fait qu'un nivellement parfait de la base du matelas constitue un atout majeur lors du transport de

ce dernier au travers des différents convoyeurs. Il est donc possible d'éviter tout accrochage entre les postes de convoyeurs et ainsi profiter d'une tenue optimale. L'effet de nivellement de la base semble donc l'emporter sur l'effet d'épaisseur du produit en fonction du calendrage effectué.

Pour continuer dans ce raisonnement logique à propos de la tenue matelas, il est intéressant d'associer au bon mélange des fibres, différents postes d'écrasement ou de compression pour garder le tout en place de façon homogène. En conséquence, deux autres variables majeures, soit la distance de la calandre de gaufrage « discal » et la pression d'aspiration de la zone « A » au tambour de formation « pression » donnent des effets très bénéfiques pour une bonne tenue matelas.

Du point de vue procédé « machine », l'agglomération primaire des fibres se fait au niveau de l'aspiration du matelas sur le tambour de formation. Cette aspiration est essentielle et est considérée dans un certain sens comme le premier poste de calendrage du matelas. Plus l'aspiration au tambour est grande, meilleurs sont les résultats de la tenue matelas. Ensuite, un peu plus loin dans le procédé, le poste d'écrasement à la calandre de gaufrage est l'endroit où le matelas prend sa pleine tenue. Selon les résultats obtenus, plus la distance d'écrasement de la calandre de gaufrage est petite, plus la tenue matelas devient grande.

Enfin, deux autres variables, moins importantes celles-là, indiquent que la tenue matelas maximum s'obtient de meilleure façon avec un nombre de pâtes plus grand en fonction d'une vitesse de production minimum. C'est logique car le temps de défibration au broyeur à marteaux est plus long donc le matelas possède une densité plus élevée. Alors, l'effet de soudage aux différents postes de calendrage est plus remarqué. Les liens de soudage entre les fibres au pouce carré sont plus nombreux qu'un matelas de plus faible densité.

4.3.1.1 INTERPRÉTATION DES RÉSULTATS

La différence des résultats entre l'analyse de sensibilité par Pareto et les calculs effectués par RDN sont très semblables. Les tendances sont restées toutes pareilles. La classification décroissante d'importance des effets a été changée pour deux variables. Les variables « pression » et « discal » se sont échangé le deuxième et troisième rang. Ces deux variables étant très près l'une de l'autre au point de vue amplitude, il n'est pas surprenant de constater ce changement et il n'est pas considéré non plus très critique.

Selon la plage des résultats obtenus par le RDN versus les valeurs des expériences sur machine, il existe une certaine similarité. Le Tableau 4.3 donne un aperçu des résultats obtenus.

Les valeurs entre parenthèses sont les valeurs extrêmes que peuvent prendre les valeurs de la variable « TM » tout en étant jugées acceptables. En fait, lors de l'entraînement du réseau de neurones, une valeur caractérisant la précision de la

variable « TM » a été déterminée. On parle ici d'une valeur nominale à plus ou moins 16% d'erreur.

	RDN	Essais « machine »
Valeur max.	603.93 (700.56)	715.625
Valeur min.	247.63 (208)	184.6
Étendue	356.3 (492.56)	531.025
Écart absolu	174.725 (38.465)	

TABLEAU 4.3: COMPARATIF DES RÉSULTATS OBTENUS SUR TM.

Cette valeur de 16% n'a pas été prise au hasard. Cette valeur correspond en fait à la valeur de l'erreur reliée à l'écart type des différentes valeurs trouvées lors des essais sur machine. Aussi cette valeur correspond à un niveau d'entraînement où le réseau généralise le mieux ses approximations en fonction des nouvelles valeurs à trouver sur toute la série de points déjà connue. Donc, chaque variable dépendante à l'étude possède une précision d'entraînement et celle de « TM » est de 16%.

Considérant certaines valeurs qu'il est possible d'atteindre par réseau de neurones, au Tableau 4.3, il est possible de voir que près de 93% de la plage théorique (valeurs aux essais « machine ») est atteinte. Ceci démontre que le RDN a bien couvert son domaine d'étude et que les résultats sont valides.

Selon les spécifications données par SCA pour la valeur de tenue matelas « TM », le RDN montre qu'il est très difficile d'obtenir la valeur cible de six cent cN. Même lors de la prise des données sur machine très peu d'expériences ont donné un chiffre près de la valeur cible.

Ce faisant, pour augmenter davantage la valeur de la tenue matelas, il est recommandé de jouer sur un autre poste intermédiaire de calandrage entre le tambour de formation et la calandre de gaufrage. Présentement, il existe sur machine un poste de pré-compression à la sortie du convoyeur situé sous le tambour de formation. Il serait intéressant de jouer sur sa hauteur et de vérifier les valeurs de « TM ».

4.3.2 TEMPS D'ACQUISITION (TA)

Cette variable dépendante, par définition de sa méthode d'analyse, consiste à déterminer la rapidité avec laquelle un liquide (solution saline à 1% NaCl) pénètre dans le produit selon trois séquences successives d'où son véritable nom d'analyse laboratoire, temps d'acquisition un, deux, trois.

Si on se fie à la définition de la méthode d'analyse laboratoire, le temps d'acquisition devrait mieux se faire avec un matelas peu calandré pour permettre au liquide de se faufiler plus rapidement au travers de ce dernier. Parmi les variables indépendantes d'influence majeure, la variable « discal » devrait être présente et c'est effectivement le cas comme le montre le Tableau 4.4.

123,233	118,503	106,564					
42,40%	10,85%	27,40%					80,65%
DISBROSS	DISCAL	PRODRATE	PRESSION	NBPATE	PROFSA	DISBREAK	TA
0	0,05	175	15	3	48	0,105	98,13
	▲	▲		▲	▲		▲
▼			▼			▼	
5	0,025	100	25	2	40	0,181	141,71

TABLEAU 4.4: CALCULS DES EFFETS PAR RDN SUR TA.

La première variable indépendante en importance d'influence est la variable « disbross ». Il est très logique de retrouver cette variable en première place puisque la distance de la brosse égalisatrice a un impact immédiat sur l'épaisseur du produit. Plus le produit est épais, plus il subit un écrasement aux différents postes de calandrage, dont celui de la calandre de gaufrage. Ce faisant, le temps devient plus long avant que le liquide se faufile entièrement à l'intérieur du matelas. On peut donc voir que les variables « disbross » et « discal » possèdent une dépendance certaine l'une envers l'autre.

L'évolution du changement de la variable dépendante montrée par les chiffres situés au haut du Tableau 4.4 démontrent aussi ce fait. En débutant le changement des données de l'ajustement considéré le pire vers l'ajustement considéré le meilleur, la première variable en influence a fait varier la variable indépendante de seulement 10.85%. Quand « discal » a été changé à son tour, une addition de près de 43% dans le changement de l'état de la variable dépendante a été notée. Il faut rappeler ici qu'en changeant les deux premières variables d'influence de rang, la même situation se créera. C'est vraiment le lien d'interaction entre ces deux variables qui produit ce phénomène. En traçant le graphe des interactions entre ces deux variables, les droites de la Figure 4.3 démontrent clairement par leurs effets entrecoupés qu'une interaction existe entre ces deux variables. Lors de l'étude prochaine de la variable dépendante de l'absorption dix pouces « ABS10 », la même situation d'interaction devrait réapparaître étant donné que les deux méthodes d'analyses laboratoire se ressemblent.

Enfin, la dernière variable indépendante d'influence sur la variable dépendante « TA » est le taux de production « prodrate ». La présence de « prodrate » peut s'expliquer par le fait que plus la machine produit rapidement, moins le temps de défibrage est long donc le broyage est plus grossier. Tout comme dans le domaine du génie civil, plus un sol possède une granulométrie fine, moins bonne sera son aptitude à absorber l'eau. La situation présentée sur machine suit la même tangente.




FIGURE 4.3: INTERACTION ENTRE "DISCAL" ET "DISBROSS"

4.3.2.1 INTERPRÉTATION DES RÉSULTATS

La différence de résultats entre l'analyse de sensibilité par Pareto et les calculs effectués par RDN est pratiquement similaire. Les grandes tendances des influences majeures sont demeurées pareilles ainsi que leurs classifications. L'analyse de sensibilité par Pareto valide donc très bien les résultats obtenus par le calcul du RDN.

Selon la plage des résultats obtenus par les calculs de RDN versus les valeurs des expériences sur machine, il existe une certaine similarité. Le Tableau 4.5 donne un aperçu des résultats obtenus.

	RDN	Essais « machine »
Valeur max.	141.71 (164.36)	149.25
Valeur min.	98.13 (82.43)	95.425
Étendue	43.58 (81.93)	53.825
Écart absolu	10.245 (28.105)	

TABLEAU 4.5: COMPARATIF DES RÉSULTATS OBTENUS SUR TA.

Tout comme pour les autres variables indépendantes « AT » et « ABS10 » il a été jugé bon d'entraîner le RDN avec une précision de 14% avec un niveau intermédiaire à trois neurones.

Il est à remarquer au Tableau 4.4 qu'avec seulement les deux premières variables d'influence, il est possible d'atteindre la cible des spécifications exigées par SCA. Selon le graphe de Pareto pour cette variable dépendante « TA », il est possible de voir une distinction précise entre les variables d'influence majeure et les autres. Il sera vu plus loin que pour l'autre variable dépendante qui ressemble à celle-ci, soit l'absorption dix pouces « ABS10 », la clarté distinctive entre les variables d'influence et les autres variables ne sera pas aussi évidente.

Par rapport au Tableau 4.5, si on considère des valeurs potentiellement atteignables par le réseau de neurones, il est possible de voir que plus de la totalité de la plage pratique (valeurs aux essais « machine ») est atteinte. Ceci démontre donc que

montré au Tableau 4.6, les variables indépendantes « prodrate » et « nbpâte » se classent respectivement au premier et au troisième rang parmi les variables ayant le plus d'influence sur le changement d'état de la variable de rétention.

La capacité de rétention d'un liquide à l'intérieur du matelas doit aussi être en fonction de la force des liens qui retiennent les fibres entre elles à l'intérieur du matelas. Il a été vu précédemment avec la variable dépendante du temps d'acquisition « TA » que la force liante des fibres du matelas était tout à fait inutile, seul la vitesse d'entrée du liquide comptait. Maintenant, avec cette nouvelle variable à l'étude, le raisonnement est quelque peu différent. La vitesse d'entrée est sans conséquence, par contre le fait de devoir retenir le liquide à l'intérieur du matelas amène à ajouter une force liante sur les fibres de ce dernier. C'est exactement ce que fait la variable indépendante de la distance de la calandre de gaufrage « discal ». Ceci explique donc le comportement de la variable « discal » qui fonctionne de façon opposée entre le temps d'acquisition « TA » et la rétention « RET ». Au Tableau 4.6, son influence sur le changement de la variable dépendante se classe au quatrième rang. Logiquement son rang devrait être plus élevé.

Ceci revient donc à dire que pour la rétention, on veut une densité de fibre au matelas la moins dense possible pour faire entrer le maximum de liquide. D'un autre côté, on doit diminuer quelque peu cette densité en effectuant un calandrage qui donnera une force liante minimale aux fibres présentes à l'intérieur du matelas. Il existe donc deux phénomènes favorisant la rétention mais travaillant dans des sens opposés. Il suffit maintenant de trouver l'ajustement optimal entre ces deux phénomènes pour tirer le meilleur de la variable de rétention.

Toujours au Tableau 4.6, la variable indépendante de la pression d'aspiration de la zone « A » au tambour de formation « pression » est présente. Cette variable indépendante, selon son rang au Tableau 4.6, est totalement surévaluée. Lors de l'analyse de sensibilité par Pareto, cette variable s'était classée au dernier rang selon son influence sur la rétention. La seule chose qui peut expliquer ce changement de rang vient de la façon dont le RDN fait ses calculs. Étant donnée que le RDN considère plusieurs variables de sortie en même temps et aussi à cause des approximations multiples qu'il a à faire, le RDN a probablement dû mettre de côté une bonne approximation sur « RET » au détriment de quelques autres variables dépendantes.

4.3.3.1 INTERPRÉTATION DES RÉSULTATS

Si on compare maintenant les résultats de l'analyse de sensibilité par Pareto aux calculs fait par le RDN, pour cette variable, certaines choses ont changé.

D'abord pour les tendances, ces dernières sont restées à peu près toutes dans les mêmes directions sauf pour une qui avait peu d'influence sur la rétention. Pour ce qui est du classement des effets d'influence, c'est une toute autre chose. Seulement une variable respecte l'ordre pour les deux analyses, c'est la variable principale du taux de production « prodrate ». Le reste des variables indépendantes ont toutes changé de

rang. Si ce n'était de la variable indépendante « pression » qui n'est pas du tout à son rang avec les calculs par RDN, les comparaisons entre les deux analyses auraient été beaucoup plus crédibles. Prenons en conséquence qu'à partir de maintenant, la variable indépendante « pression » se situe au dernier rang selon l'influence sur la variable de rétention.

Avec les résultats obtenus à partir des essais « machine », la moyenne d'erreur reliée à l'écart type est à tout près de 23%. Avec une telle grandeur d'erreur sur l'écart type il devient difficile de garder une classification des influences exactes entre ces deux analyses. Les calculs des effets par RDN donnent en plus une légère erreur supplémentaire causée par des approximations sur les différentes variables de sortie. Il est alors préférable de miser sur les classifications faites par l'analyse de sensibilité par Pareto. C'est ce qui motive aussi la décision d'envoyer la variable indépendante « pression » au dernier rang pour les influences.

Voyons maintenant à partir du Tableau 4.7, la plage des résultats obtenus par calculs du RDN en fonction des valeurs obtenues par les expériences sur machine.

	RDN	Essais « machine »
Valeur max.	265.78 (321.59)	277.125
Valeur min.	233 (184.07)	221.237
Étendue	32.78 (137.52)	55.888
Écart absolu	23.108 (81.632)	

TABLEAU 4.7: COMPARATIF DES RÉSULTATS OBTENUS SUR RET.

On peut voir au Tableau 4.7, que le pourcentage d'erreur pris pour l'entraînement était beaucoup trop grand. Dans la colonne « RDN », le différentiel de valeur entre le chiffre écrit entre parenthèses et l'autre dans la même case est trop grand. Le domaine étudié par le RDN est devenu beaucoup trop grand comparativement aux valeurs obtenues par essais « machine ». Pour cette variable, l'erreur sur les entraînements par RDN est de 21%, c'est beaucoup trop. Considérant que la moyenne des erreurs reliées à l'écart type sur les résultats obtenus par essais « machine » est de 23%, les valeurs d'erreur sur les entraînements par RDN n'avaient pas le choix d'être aux alentours de cette même valeur pour refléter la réalité.

Ceci est un autre bon exemple du manque de données reliées aux essais. Avec plus d'essais « machine », la valeur de l'erreur reliée à l'écart type sur les résultats obtenus aurait probablement été plus petite et le domaine étudié par RDN aurait été, par conséquent, aussi plus petit. Les résultats obtenus par RDN auraient donc été plus précis. Toujours en considérant les valeurs du Tableau 4,7 il y a présentement, sans considérer l'erreur à l'entraînement du RDN, près de 59% (32.78/55.888) de la plage des résultats obtenus par essais « machine » qui est couverte. Supposons maintenant une erreur raisonnable de 10% (Valeur max. de la colonne RDN devient 292.36 et valeur min. de la colonne RDN devient 209.7 pour une plage de 82.66%) sur les valeurs « machine » trouvées, dans ce cas environ 148% (82.66/55.888) de la plage des

résultats devient couverte, ce qui est excellent. Présentement 246% (137.52/55.888) de la plage des résultats est couverte, c'est beaucoup trop.

Le même phénomène se reproduit un peu plus loin lors de l'analyse de la variable dépendante du taux d'acceptables « %ACC ».

Selon les spécifications exigées par SCA, l'étendue des valeurs pour la rétention « RET » devrait se situer entre deux cent-cinquante grammes et deux cent soixante-quinze grammes. À partir des valeurs qui ont été calculées avec le RDN et des résultats qui ont été obtenus à partir des essais « machine », les valeurs de rétention se situent en moyenne tout juste en bas de la valeur cible et même parfois sous la limite inférieure de rejet. Il serait donc intéressant de trouver des points sur la machine pouvant aider à faire remonter la valeur de la rétention.

La première chose à appliquer est, comme pour le temps d'acquisition « TA » plus haut, de faire descendre quelque peu la vitesse de rotation du broyeur à marteaux pour compenser l'augmentation du taux de production nécessaire. En conséquence, il devient intéressant de descendre l'espacement de la calandre de gaufrage le plus possible sans trop déranger les valeurs des autres variables dépendantes.

Selon la classification des variables d'influence par Pareto, la variable indépendante de la profondeur de la couche de super absorbant « profsa » est une variable intéressante à considérer. En effet, le tableau des effets correspondant montre que plus le super absorbant est à la surface du matelas, meilleure devient la valeur de la rétention. Il existe une certaine logique à ce résultat. Le super absorbant prend de l'expansion lorsqu'il est en contact avec un liquide. La quantité de liquide qui réussit à se faufiler sous la couche de super absorbant devient plus difficile à faire sortir à cause de l'expansion de chaque grain de super absorbant. Plus le super absorbant est en surface, plus le volume d'eau situé à l'intérieur du matelas devient grand donc, meilleure est la valeur de rétention.

4.3.4 ABSORPTION TOTALE (AT)

La variable dépendante d'absorption totale se définit par sa méthode d'analyse laboratoire comme la quantité maximale de liquide qu'un produit fini peut absorber. À partir d'un échantillon de produit pesé à sec, on incorpore ce dernier en sandwich entre une grille de tamis et un Plexiglas. On tare la balance contenant l'ensemble décrit plus haut et on immerge le tout dans une solution saline pendant cinq minutes. À la fin de ce temps, on sort le tout de l'eau, on laisse égoutter pendant vingt secondes et on prend une lecture du poids de l'ensemble tamis-produit-plexiglass. La différence des lectures avant et après l'immersion dans le liquide constitue la valeur de l'absorption totale.

L'analyse de cette variable est quelque peu compliquée. Les résultats obtenus par calculs de RDN ne sont pas du tout ceux qui étaient attendus. Habituellement pour toutes les analyses de sensibilités faites par Pareto, les essais « machine » un à dix-huit sont considérés. Plus tard, lors des calculs par RDN, pour avoir des résultats plus

précis, les essais « machine » un à dix-neuf sont considérés également. Ainsi, il a été remarqué que lors de la dernière analyse l'essai dix-neuf venait faire changer beaucoup de choses dans le classement des influences ainsi que des tendances.

Au Tableau 4.8, on remarque que la comparaison entre l'analyse faite par Pareto et les calculs effectués par le RDN donne un résultat tout à fait différent. Aucune logique d'interprétation n'est possible sur les résultats de ce Tableau. Selon ce qui a été vu sur les analyses des autres variables dépendantes semblables, soit en fait de définition d'analyse laboratoire, il aurait été logique de s'attendre à des tendances similaires, ce qui ne fut pas du tout le cas.

1424,15 25,69%	1431,96 25,89%	1438,38 21,28%	1442,1 12,33%				85,18%
PRODRATE	DISCAL	PRESSION	NBPATE	PROFSA	DISBROSS	DISBREAK	AT
175	0,05	15	3	40	5	0,105	1446,57
↑	↑		↑		↑		↑
		↓		↓		↓	
100	0,025	25	2	48	0	0,181	1416,4

TABLEAU 4.8: CALCULS DES EFFETS PAR RDN POUR AT, ESSAI 19 INCLUS.

L'origine de cette erreur peut s'expliquer comme ceci : sur l'analyse de cette variable, même si l'erreur reliée à l'écart type est de 13% seulement, le domaine de faisabilité de « AT » doit être plus non-linéaire que certaines autres variables comme « ABS10 » ou « TA ». Ces deux dernières variables n'ayant presque pas subi de changements par rapport au dix-neuvième essai, on peut donc conclure que la topologie prise pour les calculs par RDN était bonne et valide. Considérant que la présente variable à l'étude démontre des signes de non-linéarités dans son domaine et que la topologie du réseau pour les calculs par RDN est à trois neurones intermédiaires sur un seul niveau, ceci peut expliquer le fait du manque de précision. Pour contrer ce manque de précision en fonction d'un domaine non linéaire il aurait fallu faire plus d'expériences lors des essais « machine ». Avec des domaines d'études plutôt linéaires, il est possible de s'en tirer en précision avec peu de variables connues. Pour des domaines non linéaires et une même précision, un nombre plus grand de variables connues devient nécessaire.

Dans le but de comparer des pommes avec des pommes, une série de calculs par RDN furent faits en considérant seulement les dix-huit premières expériences comme avec l'analyse de sensibilité par Pareto. Le Tableau 4.9, montre les résultats de ces calculs. Nous pouvons voir cette fois, que les résultats obtenus sont plus à la mesure des attentes que nous avions au départ et qu'ils reflètent plus l'image de l'analyse de sensibilité par Pareto.

Cette fois nous pouvons remarquer en analysant le Tableau 4.9, que la variable « disbross » est de tendance inverse par rapport à ce que nous voyons habituellement. Cette fois, la variable dépendante de l'absorption totale « AT » semble favoriser un volume de matelas maximal. Pour favoriser le plus grand volume de liquide entrant à l'intérieur du matelas, il serait intéressant d'obtenir via la distance de calandre de gaufrage, un écrasement minimal et favoriser encore une fois une densité la plus faible possible du matelas. Comme cette analyse se fait sur le matelas au complet il serait intéressant d'avoir la grande nappe¹ la plus épaisse possible et en même temps la moins calandree, dans le but de faire entrer le plus grand volume d'eau. Considérant aussi que la calandre de gaufrage a un effet plus prononcé sur la petite nappe², il semble que d'obtenir une grande nappe plus épaisse avec une plus forte compression à la petite nappe est plus profitable qu'une grande nappe mince avec une faible pression sur la petite nappe. Une région d'absorption plus grande et plus épaisse de la grande nappe est plus profitable même si la petite nappe se trouve plus comprimée par la calandre de gaufrage.

1428,5 38,85%	1433,81 25,09%	1436,58 13,09%					77,03%
DISBROSS	DISCAL	NBPATE	PROFSA	PRESSION	DISBREAK	PRODRATE	AT
5	0,05	3	40	15	0,105	175	1441,44
▲	▲	▲				▲	▲
			▼	▼	▼		
0	0,025	2	48	25	0,181	100	1420,28

TABLEAU 4.9: CALCULS DES EFFETS PAR RDN POUR AT, ESSAI 19 NON INCLUS.

Si on regarde le graphe de Pareto pour cette variable dépendante située à l'annexe 6, on peut remarquer que la distance de la brosse égalisatrice possède un effet dominant par rapport aux autres variables. Comme avec tous les autres tests laboratoire impliquant une analyse d'entrée de liquide à l'intérieur du matelas, la variable « disbross » est toujours en premier plan.

4.3.4.1 INTERPRÉTATION DES RÉSULTATS

Maintenant que seulement les dix-huit premiers essais sont considérés autant pour l'analyse de sensibilité par Pareto que par les calculs de RDN, la différence entre ces deux dernières analyses devient beaucoup plus semblable et ressemble beaucoup plus aux résultats provenant d'une analyse impliquant une entrée de liquide dans le matelas.

¹ Partie du matelas possédant la plus grande superficie des 2 étages composant le matelas.

² Partie du matelas de superficie plus restreinte localisée sur le dessus de la grande nappe.

Entre les deux analyses effectuées, on peut voir que la tendance de la variable du nombre de pâtes a changé de direction; les autres variables sont demeurées toutes dans la même direction. Pour ce qui est du classement des influences sur la variable dépendante, il y a eu des changements. La variable principale d'influence « disbross » est restée correctement classifiée. Pour les autres variables, si on regarde le graphe de Pareto situé à l'annexe 6, on peut voir que les variables du deuxième, troisième et quatrième rang sont assez près l'une de l'autre. Un mélange dans leurs classements ne serait pas étonnant car il faut considérer que le RDN fait des approximations en fonction des variables à sorties multiples. Dans une optique d'approximation sur les autres variables dépendantes, il se pourrait que la classification soit changée. Il faut noter que malgré ces changements, ça ne veut pas dire que l'étude est mauvaise pour autant, ça veut seulement dire que les variables du deuxième, troisième et quatrième rang sont trop près l'une de l'autre dans leurs valeurs.

Pour les valeurs numériques obtenues par cette variable à l'étude, le Tableau 4.10 montre la différence des valeurs obtenues entre l'analyse de sensibilité par Pareto et les calculs par RDN.

Le Tableau 4.10 montre aussi que l'étendue des valeurs trouvées par calculs de RDN n'est pas suffisamment grande par rapport à l'étendue des valeurs trouvées sur machine. Cette première observation est nettement un signe du manque de connaissance du domaine à l'étude. C'est ce qui confirme la thèse du manque d'essais « machine » mentionné plus haut dans la section précédente.

	RDN	Essais « machine »
Valeur max.	1446.57 (1643.24)	1543
Valeur min.	1420.28 (1221.44)	1270.5
Étendue	26.29 (421.8)	272.5
Écart absolu	246.21 (149.59)	

TABLEAU 4.10: COMPARATIF DES RÉSULTATS OBTENUS SUR AT.

Seulement 9.6% de la plage est couverte par les calculs de RDN, ce qui est nettement insuffisant. Si on considère les valeurs potentiellement atteignables, alors 155% de la plage se trouve couverte. On voit donc ici un manque assez important de proportionnalité entre 155% et 9.6%.

Comme il a été décrit plus haut, le fait que cette variable dépendante n'aie pas eu assez de variables tests pour faire ses calculs et bien connaître son domaine, les résultats obtenus ne veulent pas dire beaucoup et il ne serait pas de bon usage de vouloir en faire une analyse plus poussée.

4.3.5 ABSORPTION 10 POUCES (ABS10)

La prochaine variable dépendante à l'étude est celle de l'absorption dix pouces. Sa méthode d'analyse laboratoire consiste à déterminer la capacité d'absorption du produit dans la partie de l'entrejambe. La mention « dix pouces » indique que la longueur de la partie étudiée à l'entrejambe est fait sur dix pouces. Cette analyse consiste à découper le produit sur le sens transversal dans la région de l'entrejambe sur une longueur de dix pouces. La pièce analysée est mise en sandwich entre un tamis et un morceau de plexiglass et le tout est ensuite pesé pour tarer la balance. On immerge l'ensemble dans un liquide pour cinq minutes, on sort ensuite le tout, et, après vingt secondes le poids est noté. La différence de poids indique la quantité absorbée par le produit.

Encore une fois ici, quand il est question d'absorption, on peut penser au phénomène de granulométrie du sol. Plus la granulométrie est grossière, meilleure devient l'absorption de l'eau dans le sol. De la même façon pour la formation du matelas, quelques facteurs mis ensemble font en sorte de favoriser un matelas moins dense donc plus apte à faire entrer le liquide. Une combinaison intéressante de variables pouvant favoriser une basse densité de matelas est:

- Une distance de la calandre de gaufrage élevée associée à une distance de brosse égalisatrice basse.
- Un nombre de pâtes élevé associé à un taux de production élevé.

La logique derrière les deux points précédemment mentionnés est simple. D'abord pour le premier point, plus la distance de la brosse égalisatrice est près du tambour de formation, plus le matelas produit est mince. Considérant que la calandre de gaufrage est toujours ajustée au même niveau, alors il est logique de conclure que pour une même distance de calandre de gaufrage, un matelas plus mince est moins calandré et favorise ainsi une plus faible densité du matelas.

Pour ce qui est de l'autre point, il a été mentionné déjà dans l'analyse sur d'autres variables dépendantes que plus la vitesse de production est élevée et que le nombre de pâtes entrant au broyeur à marteaux est grand, plus le broyage se fait de façon grossière. Cet effet ne serait probablement pas présent si la vitesse du broyeur à marteaux était variable.

Parmi les variables indépendantes nommées auparavant, la plupart se retrouvent parmi celles ayant les plus grandes influences sur le changement d'état de la variable de l'absorption dix pouces « ABS10 ». La classification de ces variables est donnée au Tableau 4.11.

522,64 5,81%	557,31 28,69%	611,08 44,49%					78,99%
DISBROSS	DISCAL	DISBREAK	NBPATE	PRODRATE	PROFSA	PRESSION	ABS10
0	0,05	0,105	3	175	48	15	636,47
	▲		▲	▲	▲		▲
▼		▼				▼	
5	0,025	0,181	2	100	40	25	515,62

TABLEAU 4.11: CALCULS DES EFFETS PAR RDN POUR ABS10.

Une variable possédant une influence sur le changement d'état de l'absorption dix pouces et qui est difficilement interprétable est la variable de la distance du breaker bar « disbreak ». On pourrait croire qu'il y a erreur avec cette variable mais pourtant elle est classifiée presque au même endroit autant sur l'analyse de sensibilité par Pareto que par calculs de RDN. Après avoir vu l'ensemble des tableaux situés à l'annexe sept sur la feuille intitulée « Tableaux des effets calculés par RDN », les tendances pour cette variable semblent donner une indication. On peut voir que pour chaque variable dépendante nécessitant une faible densité de matelas, une distance de « breaker bar » plus courte est favorisée. Seule la tenue matelas montre une tendance inverse, c'est normal puisque la solidité du matelas repose sur un matelas dense donc bien calandré. On ne connaît pas encore d'explication logique à ce phénomène mais les tableaux montrent bien la tendance.

4.3.5.1 INTERPRÉTATION DES RÉSULTATS

Pour cette variable dépendante, il n'existe pas beaucoup de différence entre l'analyse de sensibilité par Pareto et les calculs faits par RDN. En fait seul deux variables ont changé de rang pour ce qui est de l'influence. Si on regarde le graphe de Pareto pour cette variable, on voit que les deux premières variables indépendantes se démarquent vraiment du reste des autres variables. Le fait d'inverser le rang des variables en troisième, quatrième ou cinquième position n'est toujours pas critique. Ces variables sont tellement près l'une de l'autre selon leurs valeurs que le RDN, dans ses approximations, pourrait facilement inverser leur position.

Pour les tendances, c'est la même chose. Deux variables ont changé d'orientation par rapport aux deux analyses comparées. En regardant le graphe des effets situé à l'annexe cinq, les deux variables ayant changé leurs tendances ne possédaient pas de pente bien définie. Encore une fois, le RDN avec ses approximations aurait pu tout aussi bien inverser les tendances assez facilement. Si ces phénomènes s'étaient produits sur les deux variables les plus influentes, il y aurait eu raison de s'inquiéter, mais sur les autres, ce n'est pas trop grave. On peut quand même affirmer que pour cette variable, la validation des résultats entre les deux analyses s'est bien faite.

Analysons maintenant les plages de résultats obtenues par les deux analyses effectuées. D'abord jetons un coup d'œil sur le Tableau 4.12.

	RDN	Essais « machine »
Valeur max.	636.47 (725.57)	662.5
Valeur min.	515.62 (443.43)	506
Étendue	120.85 (282.14)	156.5
Écart absolu	35.65 (125.64)	

TABLEAU 4.12: COMPARATIF DES RÉSULTATS OBTENUS SUR ABS10.

La différence des résultats entre ces deux analyses est quand même satisfaisante. Notons ici que l'entraînement par RDN s'est fait avec une approximation des résultats de 14%. Sans considérer les valeurs potentiellement atteignables mises entre parenthèses, 77% (120.85/156.5) de la plage calculée par le RDN est couverte. Si on considère les valeurs potentiellement atteignables alors 180% (282.14/156.5) de la plage se trouve couverte. À 180%, la plage commence à être large et les valeurs de moins en moins crédibles au fur et à mesure que le pourcentage augmente. À partir de ce qui a été observé lors de l'analyse des autres variables dépendantes, une plage couverte entre:

- 100% et 150% est excellente pour l'extrapolation du domaine étudié.
- 150% et 200% commence à être dangereux pour la crédibilité des résultats.
- Plus de 200%, ça devient alors catastrophique et non crédible.

Sur un autre ton maintenant, il est possible de voir sur le graphe des calculs des effets par RDN au Tableau 4.11, que la troisième variable en influence soit « disbreak » possède un pourcentage d'augmentation d'influence assez important à 44.49%. Comme vu précédemment sur l'analyse des autres variables dépendantes, quand un pareil cas se produit, c'est qu'il y a des signes d'interdépendance entre cette variable et celle qui la précède. Dans le présent cas, est-ce qu'il y a une forte interdépendance avec la variable « discal » seulement ou avec « discal » et « disbross » ou pas d'interdépendance du tout? Le fait qu'il soit difficile d'expliquer ou d'interpréter la présence de « disbreak » parmi ces variables d'influence ne permet pas de répondre adéquatement à la question posée plus haut. Par contre si on regarde dans l'ensemble les tableaux d'effets calculés par RDN et les tendances, on voit qu'il existe une explication mais quelle est-elle?

4.3.6 DÉFIBRATION (%ACC)

Par définition le test de défibration de la ouate consiste à analyser la qualité de défibration en faisant une classification des fibres de l'ouate. Les fibres peuvent être classifiées selon trois catégories possédant un pourcentage:

- de nœuds (petite boule d'ouate).
- de fines ou poussières.
- d'acceptables (quantité maximale recherchée).

Cette variable est probablement la plus énigmatique pour ce qui est de son analyse et de son interprétation. Comme montré au Tableau 4.13, le taux d'acceptables en défibration « %ACC » possède quand même quatre variables d'influence majeure ayant un effet sur sa valeur finale. En ordre décroissant d'influence, il y a d'abord le taux de production « prodrate », la pression d'aspiration de la zone « A » sur le tambour de formation « pression », la distance de la calandre de gaufrage « discal » et le nombre de pâtes « nbpâte ».

84,012 23,16%	84,158 25,61%	84,288 22,81%	84,37 14,39%				85,96%
PRODRATE	PRESSION	DISCAL	NBPATE	DISBREAK	DISBROSS	PROFSA	%ACC
175	15	0,025	3	0,105	5	40	84,45
▲			▲		▲		▲
	▼	▼		▼		▼	
100	25	0,05	2	0,181	0	48	83,88

TABLEAU 4.13 CALCULS DES EFFETS PAR RDN POUR %ACC.

Selon ce qu'il est logique de croire, la variable de la distance du breaker bar « disbreak » doit être la variable la plus influente dans les changements de valeurs de « %ACC » mais ce n'est pas le cas. L'explication de ce phénomène peut être que la pâte en matière première est livrée déjà pré-défibrée et tenue par un liant temporaire en attendant d'être transformée en ouate. Il est alors sensé de penser que la variable « disbreak » n'aie pas un si grand impact. Le rotor du broyeur à marteaux sert alors comme premier outil pour déchirer la pâte et défaire le liant qui retient les fibres.

4.3.6.1 INTERPRÉTATION DES RÉSULTATS

Si on compare les résultats obtenus par les calculs de RDN par rapport aux valeurs des expériences faites sur machine, il existe beaucoup de différences. Selon les variables d'influence majeure parmi les variables indépendantes, les variables « pression » et « discal » ont subi un inversement de leurs tendances. Le plus étonnant parmi ces changements est que la variable indépendante « disbreak » qui était considérée comme une variable d'influence majeure avec sa deuxième position, vient maintenant, lors des calculs par RDN, de tomber au cinquième rang et ne figure plus parmi les variables d'influence majeure faisant la couverture d'au moins 80% de l'étendue des données.

D'autres étranges observations constatées lors de l'analyse des calculs par RDN est que la variable indépendante de la distance d'ajustement de la calandre de gaufrage « discal » est considérée au troisième rang en importance pour son influence sur la variable dépendante « %ACC ». Ce phénomène est tout à fait ridicule quand on pense que l'analyse des fibres est faite à partir d'un échantillon pris directement dans la chambre de formation. Les fibres n'ont donc jamais passé au travers la calandre de gaufrage. La différence dans les valeurs trouvées sur « discal » vient probablement de l'influence de la variable « prodrate » ou « pression ». On se souvient que l'échantillon de fibres est toujours prélevé une fois l'essai terminé. Peut-être qu'un essai réalisé trop rapidement a empêché la chambre de formation de se vider complètement, laissant ainsi le temps à certaines fibres provenant des autres essais de s'infiltrer dans le nouvel essai. Tout cela pour conclure que la confiance relative aux résultats obtenus pour cette variable dépendante est faible.

La difficulté principale d'analyse de cette variable vient du fait que la plage des valeurs trouvées lors des essais « machine » est très peu élevée tandis que la moyenne d'erreurs reliée aux écarts types pour l'ensemble des expériences est relativement grande. Lors des tests faits sur machine, les valeurs moyennes pour chacune des expériences variaient entre 79.2% et 88.2% pour une étendue totale de neuf. Enfin l'erreur moyenne reliée à l'écart type pour toutes les expériences se situe à 23.7%, ce qui commence à être beaucoup. Considérant ce fait, le RDN a pour sa part plus de difficulté à modéliser les tendances de la variable « %ACC ». Voyons maintenant au Tableau 4.14 les valeurs comparatives des résultats pour chaque provenance:

	RDN	Essais « machine »
Valeur max.	84.45 (102.18)	88.2
Valeur min.	83.88 (66.26)	79.2
Étendue	0.57 (35.92)	9
Écarts absolus	8.43 (26.92)	

TABLEAU 4.14: COMPARATIFS DES RÉSULTATS OBTENUS SUR %ACC.

Dans le cas de cette analyse par réseau de neurones, la précision sur l'entraînement fut de 21%. C'est légèrement inférieur à l'erreur reliée à l'écart type de 23.7% trouvée avec les valeurs des résultats « machine » mais c'est quand même le pourcentage qui a donné le moins d'erreurs par rapport aux variables tests essayées.

Selon les spécifications exigées par SCA, pour la variable dépendante « %ACC », le pourcentage d'acceptables devrait se situer entre 73% et 80% (cible visée). Une affirmation à propos de cette variable est que pour tous les essais effectués, peu importe la condition de la machine, les résultats ont toujours été très satisfaisants. À preuve, la plus basse valeur de « %ACC » étant de 79.2%.

La qualité de la recherche pour cette variable dépendante est plutôt limitée. Le manque de données pour bien cadrer l'étendue et la complexité du domaine d'étude s'est fait sentir. La confiance sur l'importance de l'influence des variables indépendantes est aussi limitée. Ce qu'il faut retenir de cette étude est la classification générale des variables d'influence, surtout celles des extrémités soit la plus grande et la plus pauvre. Les quatre ou cinq variables médianes se valent presque toutes et aucune conclusion logique ne pourrait en sortir.

CHAPITRE V

CONCLUSION

5.1. CONCLUSION DE L'ANALYSE DES VARIABLES DÉPENDANTES

Pour faire suite à cette analyse exhaustive de chaque variable dépendante, trois phénomènes d'analyse ont été rencontrés. D'abord, les variables correctement simulées, soit celles où aucun problème majeur n'est survenu; ensuite les variables possédant une trop grande erreur reliée à l'écart type et enfin les variables avec une erreur d'interprétation trop grande causée par une non-linéarité.

La connaissance de ces types de problèmes s'est faite un peu par erreur. C'est en faisant l'analyse de sensibilité par Pareto avec les dix-huit premiers essais « machine » et en comparant ces résultats avec les dix-neuf essais globaux des calculs par RDN. Il a alors été possible de se rendre compte rapidement de la robustesse du domaine étudié en ajoutant seulement un essai de plus à l'analyse originale. Donc, en enlevant et en ajoutant cet essai, il a été possible de se rendre compte des effets de linéarité.

D'abord, pour les variables dépendantes ayant obtenu un bon comportement par rapport à leur degré de validité entre les deux analyses effectuées, on voit que les caractéristiques communes pour chacune de ces variables ont été de posséder un caractère plutôt linéaire avec une faible erreur reliée à l'écart type ainsi qu'une bonne étendue de valeurs limitant le domaine d'étude. Parmi ces variables, on retrouve le temps d'acquisition « TA », la tenue matelas « TM » et l'absorption dix pouces « ABS10 ». Pour ces types de variables dépendantes, il est possible d'avoir une entière confiance autant dans les valeurs trouvées par RDN que dans la classification des influences et des tendances.

Ensuite, vient le cas de la variable dépendante possédant une erreur reliée à l'écart type trop grande. Ce cas est celui de la variable dépendante du taux de fibres acceptables « %ACC ». Les caractéristiques de ce type d'analyse sont que la variable étudiée possède principalement une trop grande erreur reliée à l'écart-type des valeurs trouvées. On peut s'apercevoir aussi, et contrairement au cas du problème de non-linéarité, que ce présent cas fait en sorte que la classification des variables d'influence n'est pas trop chambardée. Pour contrer ce problème, il n'y a pas vraiment d'autre remède que celui de prendre plus de données lors des essais « machine ». Pour ce type de problème, on ne peut se fier véritablement aux valeurs trouvées par calculs via le RDN, par contre le classement des variables d'influence ainsi que les tendances sont plutôt fiables.

Enfin, il y a le problème des variables dépendantes résultant d'un domaine d'étude et d'un comportement non linéaire. C'est le cas ici des variables de la rétention « RET » et de l'absorption totale « AT ». Ce problème rencontré est certainement le plus majeur lors des analyses. Ce type de problème se caractérise en particulier par le classement des variables d'influence qui devient tout à l'envers. Par exemple, sur l'analyse de sensibilité de Pareto, une variable est classée au premier rang quant à son influence et

ensuite avec les calculs par RDN cette même variable se retrouve au dernier rang. D'un autre côté, les tendances des variables indépendantes ne sont pas nécessairement aussi mélangées, seul les amplitudes des influences sont mélangées. Le remède à ce type de problème se traite en deux temps. D'abord lors des calculs par RDN, il faut donner une topologie au réseau favorisant les non-linéarités. Présentement la situation est décrite par peu d'expériences « machine » avec peu de neurones intermédiaires, ce qui favorise l'analyse des comportements linéaires. Si on doit garder le nombre de neurones intermédiaires aussi bas pour toujours garder l'erreur d'analyse près de celle reliée à la variance des résultats « machine », il faut alors augmenter le nombre des essais « machine ». Sinon l'autre alternative pourrait être de faire passer de deux à trois le nombre de niveaux sur le plan expérimental. Avec ce type de problème on ne peut pas se fier véritablement aux valeurs trouvées ainsi qu'au classement des influences.

5.2. CONCLUSION DE L'ANALYSE DES VARIABLES INDÉPENDANTES

Dans ce sous-chapitre, le tableau final récapitulatif provenant des informations de chaque tableau des effets sur les variables dépendantes vues au chapitre quatre est analysée. En fonction de l'analyse de ce tableau, chaque variable indépendante est analysée et chacun des effets est mentionné.

	TM	TA	RET**	AT	ABS10	ACC
DISCAL	2 DOWN	2 UP	2 DOWN	2 UP	2 UP	3 DOWN
PROFSA			3 DOWN			
PRESSION	3 UP					2 DOWN
NBPATE	4 UP		4 UP	3 UP		4 UP
DISBREAK					3 DOWN	
PRODRATE		3 UP	1 UP			1 UP
DISBROSS	1 DOWN	1 DOWN		1 UP	1 DOWN	

TABLEAU 5.1: RÉSULTATS GLOBAUX DES EFFETS.

**= CLASSEMENT PRIS À PARTIR DE L'ANALYSE DE SENSIBILITÉ DE PARETO.

On voit ici l'utilité d'avoir pris pour chaque tableau des effets, les variables comptant pour 80% des effets seulement. Au premier coup d'œil, on voit immédiatement comment la mise en route optimale doit s'orienter sans se préoccuper des variables d'importance secondaire. Ceci permet de voir quelles variables indépendantes ont le plus d'influence.

DISTANCE DE LA CALANDRE DE GAUFRAGE (DISCAL)

- A un effet immédiat sur la densité du matelas au niveau du petit matelas. Plus l'ajustement est haut, moins la densité du matelas est grande. Ce type d'ajustement est utile pour le temps d'acquisition « TA », l'absorption totale « AT » ou l'absorption dix pouces « ABS10 » par exemple.

- Son ajustement en hauteur toujours constante fait en sorte que cette variable est toujours intimement reliée avec la distance de brosse égalisatrice « disbross ».
- Son ajustement bas permet de bien écraser le matelas et de créer des liens solides entre les fibres. La tenue matelas en est un bon exemple de même que pour la rétention.

LA PROFONDEUR DE SUPER ABSORBANT (PROFSA)

- À cause de son unique contribution majeure à la variable dépendante de la rétention, la mise en course optimale théorique considérera un ajustement bas de cette variable dans sa recherche de valeur optimale.

LA PRESSION D'ASPIRATION DE LA ZONE A (PRESSION)

- Une haute pression d'aspiration de la zone « A » favorise une formation solide du matelas sur le tambour de formation. Cela est vu comme une simulation de poste de calendrage.
- Une basse pression d'aspiration de la zone « A » facilite, par contre, le travail du dépoussiéreur Osprey qui s'occupe de tirer les particules de poussière. Plus la pression est basse, plus l'Osprey a le temps de tirer les poussières. Ceci augmente nécessairement le taux d'acceptables dans le matelas.
- Pour l'étude des valeurs de mise en route optimale, il est alors de bon usage de favoriser une basse pression.

LE NOMBRE DE PÂTES (NBPATE)

- Associé à une vitesse plus élevée, son nombre élevé permet à une plus grande quantité de pâte d'entrer à l'intérieur d'un broyeur à marteaux fonctionnant toujours avec une vitesse de rotation constante.
- Pour la recherche de la valeur de mise en route optimale, l'ajustement de la valeur de départ est mis comme valeur haute à trois.

LA DISTANCE DU « BREAKER BAR » (DISBREAK)

- Cette variable possède une influence majeure seulement sur la variable de l'absorption dix pouces « ABS10 ». On sait que cette variable possède un effet bénéfique sur la défibration de la pâte mais il est très difficile d'en expliquer le pourquoi. Cette variable est ajustée en fonction de sa valeur basse pour trouver l'optimale.

LE TAUX DE PRODUCTION (PRODRATE)

- En collaboration avec le nombre de pâtes, il favorise un broyage plus ou moins grossier selon l'ajustement pris.
- Une vitesse de production plus basse avec un nombre de pâtes toujours aussi élevé (trois) favorise la formation d'un matelas plus solide.
- La valeur de départ de mise en route optimale pour cette variable est affectée à sa valeur la plus haute soit « trois ».

LA DISTANCE DE LA BROSSE ÉGALISATRICE (DISBROSS)

- En collaboration avec la calandre de gaufrage, elle permet de jouer sur la densité du matelas.
- Elle permet un nivellement parfait de la base pour solidifier le matelas lors des transferts de postes sur les convoyeurs.
- Pour l'étude de la recherche de la mise en route optimale, l'ajustement au niveau bas (zéro) est favorisé.

5.3. VALEURS DE MISE EN ROUTE OPTIMALE

Le but de cet exercice n'est pas de donner à SCA une série de valeurs de mise en route optimale qui est coulée dans le béton. Comme on le sait déjà, la crédibilité des valeurs pour certaines variables dépendantes est plutôt faible. Le but de cet exercice est de donner un aperçu par rapport aux tendances de ce que devraient être les valeurs de mise en route optimale. On sait aussi déjà que les variables du nombre de pâtes ainsi que le taux de production sont très intimement reliées et qu'il ne serait pratiquement pas possible de changer l'une ou l'autre des valeurs sans affecter le poids du matelas. Cet exercice n'est qu'un moyen de montrer quelles sont les tendances des valeurs de mise en route et comment un RDN peut travailler avec des variables à sorties multiples.

Au début de l'analyse les variables de départ sont ajustées selon les niveaux suivants:

Variables indépendantes	Valeurs
Distance de la calandre de gaufrage	0.035
Profondeur du super absorbant	40
Pression d'aspiration de la zone « A »	15
Nombre de pâtes	3
Distance du « breaker bar »	0.105
Taux de production	175
Distance de la brosse égalisatrice	0

TABLEAU 5.2: VALEURS DE DÉPART POUR L'ANALYSE.

En fonction le RDN trouve les résultats suivants:

Variables dépendantes	Valeurs
Tenue matelas	477.76
Temps d'acquisition	103.19
Rétention	263.23
Absorption totale	1433.2
Absorption dix pouces	619.44
Taux d'acceptables	84.39

TABLEAU 5.3: VALEURS OBTENUES AVEC LES VALEURS DE DÉPARTS.

Selon les spécifications exigées par SCA, on voit que la tenue matelas est nettement insuffisante, son minimum à obtenir étant de six cents. On peut aussi essayer d'améliorer quelque peu la valeur de la rétention qui se retrouve à peu près à la limite inférieure requise. En jouant sur les variables indépendantes pour faire augmenter la tenue matelas, on voit que certaines autres valeurs de variables dépendantes ayant comme caractéristiques de mesurer une absorption de liquide subissent une baisse. Il faut donc trouver un juste milieu pour accommoder toutes les autres variables dépendantes.

Variables indépendantes	Valeurs
Distance de la calandre de gaufrage	0.025
Profondeur du super absorbant	40
Pression d'aspiration de la zone A	20
Nombre de pâtes	3
Distance du « breaker bar »	0.105
Taux de production	175
Distance de la brosse égalisatrice	0

TABLEAU 5.4: VALEURS FINALES POUR L'ANALYSE.

Les résultats correspondant à cette analyse sont:

Variables dépendantes	Valeurs
Tenue matelas	545.21
Temps d'acquisition	105.71
Rétention	261.17
Absorption totale	1429.5
Absorption dix pouces	607.74
Taux d'acceptables	84.37

TABEAU 5.5: VALEURS OBTENUES AVEC LES NOUVELLES VALEURS.

Pour augmenter la valeur de la tenue matelas il n'était possible, finalement, que de jouer avec la distance de calandre de gaufrage et la pression d'aspiration dans la zone « A ». Il s'agissait des seules variables avantageuses à prendre sans briser de façon majeure les valeurs des autres variables dépendantes. La tenue matelas n'a toujours pas atteint sa valeur minimale, par contre, il y a une bonne amélioration sans altérer les valeurs des autres variables.

Les valeurs du Tableau 5.4 montrent les tendances principales que devrait avoir la mise en course pour donner de bons résultats sur la majorité des variables. Il ne reste qu'à vérifier de façon pratique si cette mise en course est techniquement possible.

5.4. CONCLUSION GÉNÉRALE

Suite à l'analyse des résultats qui s'est effectuée dans le présent document, on peut arriver à quelques conclusions majeures.

Dans un premier temps, les résultats obtenus par calculs de RDN sur les différentes variables dépendantes n'ont pas été satisfaisants dans tous les cas. La source de cette erreur provient principalement du chercheur et de son inexpérience avec les types de designs expérimentaux. Le design expérimental du factoriel fractionné ne fut pas le bon choix. La raison principale est que certaines variables dépendantes se sont avérées avoir des tendances plutôt non linéaires ce qui n'est pas la force du design choisi. Les variables dépendantes possédant ce caractère non linéaire en ont fait la preuve. Les variables affectées par ce type de problème furent la rétention « RET » et l'absorption totale « AT ». En plus le nombre d'expériences effectuées sur machine ne fut pas suffisant. Un nombre d'expériences « machine » autour de trente-six aurait grandement aidé à mieux définir le domaine étudié. La principale variable affectée par ce type de problème fut celle du taux de fibres acceptables « %ACC ».

Pour les autres variables possédant des tendances plus linéaires, les calculs par RDN ont donné des résultats intéressants. Ce fut le cas pour les variables du temps d'acquisition « TA », de la tenue matelas « TM » et de l'absorption dix pouces « ABS10 ». Avec ces variables, il a été possible de pouvoir déterminer tout le domaine

possible de faisabilité de chaque variable dépendante étudiée et de sortir des résultats crédibles.

Donc, n'eût été du mauvais choix de design expérimental, la recherche aurait été quasi parfaite. Le nombre d'expériences supplémentaires aurait été plus grand en accord avec le choix du nouveau design expérimental.

Pour ce qui est de l'interprétation des effets des différentes variables indépendantes par rapport aux variables de sortie, deux tendances principales fonctionnant chacune dans des sens opposés ont été observées

Dans un premier temps, il a été vu que toutes les variables dépendantes ayant comme méthode d'analyse une quantité de liquide à faire entrer dans le matelas, possèdent toutes les mêmes tendances. Ces variables sont celles du temps d'acquisition « TA », de la rétention « RET », de l'absorption totale « AT » et l'absorption dix pouces « ABS10 ». Ces variables ont tout en commun de viser une densité de matelas la plus faible possible, ce qui veut dire une distance de brosse égalisatrice basse associée avec une distance de calandre de gaufrage haute et/ou un nombre de pâtes élevé associé à un taux de production élevé.

De l'autre côté, il y a la variable possédant les propriétés inverses, soit la tenue matelas « TM ». Cette variable demande un calandrage serré avec une défibration de la pâte la plus complète possible, donc une densité de matelas la plus élevée possible. Il est de ce fait impossible de satisfaire aux exigences de toutes ces variables en même temps alors dans les valeurs de mise en route, il faudra probablement sacrifier une variable dépendante au profit de quelques autres.

Enfin il reste toujours la variable indépendante de la distance du « breaker bar » « disbreak » qui selon les résultats obtenus montre que sa valeur à la position basse donne une défibration qui est plus grossière. Le problème est qu'aucune explication logique n'a pu être formulée pour expliquer son comportement.

Pour conclure le tout, après avoir fait cette série d'expériences sur la machine Palmer, nous sommes tout à fait convaincus maintenant que la technologie de calculs par RDN pourrait très bien s'appliquer ailleurs sur d'autres problèmes de procédé à l'intérieur de chez SCA. Les choses essentielles à comprendre pour bien faire fonctionner un RDN sont premièrement, de faire un choix judicieux du plan expérimental à prendre et ensuite effectuer les entraînements du réseau en fonction de l'image donnée par les données recueillies sur machine. Avec ces conditions, il sera très difficile de rater son coup.

LISTE DES RÉFÉRENCES

1. Data & Analysis Center for Software, "Artificial Neural Networks Technology",
<http://www.dacs.dtic.mil/techs/neural/>
2. Schmidt Stephen R. et Launsby Robert G., "Understanding Industrial Designed Experiments", éditions Air Academy press & associates 4^e édition, Colorado Spring Co, 1998.
3. Haykin Simon, "Neural Networks, A Comprehensive Foundation", éditions Macmillan College Publishing Company inc., New-Jersey, 1994.
4. Gornik M., Novak G. et Govekar E. , "Modelling coated paper properties : application of neural networks",
[International Journal of Systems Science](#), vol.28, n^o.9, 1997, p.865-870.
5. Gheorghita J. et Lavric V., "The artificial neural networks and the drying process modeling",
[Drying Technology](#), vol.13, 1995, p.1579-1586.
6. Scharcanski J. et Dodson C.T.J., "Neural Network Model for Paper-Forming Process",
[IEEE Transactions on Industry Applications](#), vol.33, n^o.3, Mai/Juin 1997, p.826-838.
7. Cristina H., Aguiar I.L. et Filho M., "Modeling and optimization of pulp and paper processes using neural networks",
[Computers in Chemical Engineering](#), vol.22, 1998, p.S981-S984.
8. Miyanishi T. et Shimada H., "Using neural networks to diagnose web break on a newsprint paper machine",
[Tappi Journal](#), vol.81, n^o.9, Septembre 1998, p.163-170.
9. Zhu J., Xia Q., Rao M., et Zurcher J., "A neural network for modeling pulp process",
[Pulp and Paper Canada](#), vol.98, n^o.9, Sept. 1997, p.35-38.
10. Glorfeld Louis W. , "A methodology for simplification and interpretation of backpropagation-based neural network models",
[Expert systems with applications](#), vol.10, n^o 1, 1996, p.37-55.
11. McAnany D.E., "Practical applications of artificial neural networks in chemical process development",
[ISA Transactions](#), vol.32, 1993, p.333-337.

-
12. Bourquin J., Schmidli H., Van Hoogevest P., Leuenberger H., "Comparison of ANN with classical modelling techniques using different experimental designs and data from a galenical study on a solid dosage form",
European journal of pharmaceutical sciences, vol.6, n°.4, 1998, p.287-303.
 13. Montgomery Douglas C., "Design and analysis of experiments", John wiley and sons inc. 3rd edition New York, NY 1991.
ISBN 0-471-52000-4
 14. Auteur inconnu., "Overview of genetic algorithms",
<http://lancet.mit.edu/~mbwall/presentations/IntroToGAs/p001.html>
 15. Sipper M., "A brief introduction to genetic algorithms"
http://lsisun.epfl.ch/~moshes/ga_main.html
 16. Weisman O., Pollack Z., "Neural Network Using Genetic Algorithms",
<http://www.cs.bgu.ac.il/~omri/NNUGA>
 17. Auteur inconnu., "The Quasi-Newton method",
http://www.ncl.ac.uk/cpact/neural_networks.html
 18. Auteur inconnu., "Hessian matrix theory",
<http://www.iue.tuwien.ac.at/diss/plasun/diss/node71.html>
 19. Auteur inconnu., "The simplex method",
http://www.multisimplex.com/simplex_m.htm

BIBLIOGRAPHIE

- Auteur inconnu., "Neural Networks in mini steel mills",
http://www.atd.siemens.de/metals_mining_more/htmn0297/neuraln.html.
- Auteur inconnu., "Neural Network Technology Moves Toward Mainstream Control Use ",
Pulp and Paper, Avril 1998, p.63-68.
- Bergdoll S., Koch U-T., "Biosim- A biological neural network simulator for research and teaching, featuring interactive graphical user interface and learning capabilities",
Neurocomputing, vol.8, n°1, 1995, p.93-113.
- Cheng C.S., "A multi-layer neural network model for detecting changes in the process mean",
Computers in Industrial Engineering, vol.28, n°1, 1995, p.51-61.
- Doebelin Ernest O., "Engineering Experimentation Planning, Execution, Reporting",
 éditions McGraw-Hill inc., New-York N.Y., 1995.
- Drossu R., Obradovic Z., Fletcher J., "A flexible graphical user interface for embedding heterogeneous neural network simulators",
IEEE transactions on education, vol.39, n°3, 1996, p.367-375.
- Gielen C.C.A.M., Glasius R. et Komoda A., "Interpretation of neuronal activity in neural network",
Neurocomputing, vol.12, n°2, 1996, p.249-267.
- Haddad F., Hagel K. et al., "Impact parameter determination in experimental analysis using a neural network",
Physical review-Section C-Nuclear physics, vol.55, n°3, 1997, p.1371-1376.
- Jarmulak J., Spronck P. et Kerckhoffs E.J.H., "Neural networks in process control : model-based and reinforcement trained controllers",
Computers and Electronics in Agriculture, n°18, 1997, p.149-166.
- Kavchak M., Budman H. , "Adaptive neural network structures for non-linear process estimation and control",
Computers and chemical engineering, vol.23, n°9, 1999, p.1209-1229.
- Leber J-F, Jarosch A., "Opensim: A flexible distributed neural network simulator with automatic interactive graphics",
Neural networks, vol.10, n°4, 1997, p.693-705.
- Manukian N., Neuhaus J. et Wilensky G., "Multi-parameter process prediction with neural networks",
ISA Transactions, vol.33, 1994, p.329-338.

McCormick A.C. et Nandi A.K., "Classification of the rotating machine condition using artificial neural networks",
Journal of Mechanical Engineering Science, vol.211, n°6, Part C, 1997, p. 439-450.

Mitchell J., "A geometric interpretation of hidden layer units in feedforward neural networks",
Network-Computation in neural systems, vol.3, n°1, 1992, p.19-25.

Mukherjee A. et Deshpande J.M., "Modeling Initial Design Process using Artificial Neural Networks",
Journal of Computing in Civil Engineering, vol.9, n°3, Juillet 1995, p.194-200.

Mutlukan E., Keating D., "Visual field interpretation with a personal computer based neural network",
Eye-Transactions of the OSUK, vol.8, n°3, 1994, p.321-324.

Neelakantan R. et Guiver J., "Applying neural networks",
Hydrocarbon Processing, Septembre 1998, p.91-96.

Pham D.T. et Oztemel E., "An integrated neural network and expert system tool for statistical process control",
Journal of Engineering Manufacture, vol.209, n°B2, 1995, p.91-97.

Reddy D.C., Ghosh K., Vardhan V.A., "Identification and Interpretation of Manufacturing Process Patterns through Neural Networks".
Mathematical Computing Modelling, vol.27, n°5, Octobre 1997, p.15-36.

Tay K.M., "RENA—A software toolkit for experimental designs incorporating neural networks analyser",
Quality and reliability engineering international, vol.13, n°2, 1997, p.71-83.

Turner P., Montague G.A. et Morris A.J., "Neural networks in process plant modelling and control",
Computing and Control Engineering Journal, Juin 1994, p.131-134.

Wu W-T, Ko J-W., "Applications-A neural network decoupler for multivariable control",
Process control and quality, vol.11, n°3, 1998, p.211-223.

Zorriassatine F. et Tannock D.T., "A review of neural networks for statistical process control",
Journal of Intelligent Manufacturing, n°9, 1998, p.209-224.

ANNEXE 1 **FEUILLE DE RÉSULTATS D'ESSAIS PALMER**

ESSAI	1				2				3				4			
TENUE MATELAS (cN)																
1) TM	283,2				637				216,4				390,6			
2) TM	296,4				579,1				238,7				385			
3) TM	309,8				507,9				264,2				448,6			
4) TM	268,7				713,5				244,3				301,2			
Moyenne TM	289,525				609,375				240,9				381,35			
TEMPS D'ACQUISITION (sec.)																
1) TA1 / TA2 / TA3 / TTA	25,06	48,97	53,97	128	16,16	39,84	44,84	100,84	22,75	41,5	45,47	109,72	22,43	47,3	51,71	121,44
2) TA1 / TA2 / TA3 / TTA	25,12	50,29	57,63	133,04	14,97	38,25	43,09	96,31	23,29	46,88	54,28	124,45	21,36	48,74	56,37	126,47
3) TA1 / TA2 / TA3 / TTA	25,43	50,16	56,78	132,37	15,94	39,84	47,28	103,06	19,82	45,19	51,06	116,07	19,96	36,08	42,86	98,9
4) TA1 / TA2 / TA3 / TTA	25,22	53,44	60,69	139,35	20,09	45,94	52,75	118,78	24,81	43,78	47,84	116,43	23,46	38,27	42,96	104,69
Moyenne TTA	133,19				104,7475				116,6675				112,875			
RETENTION (g)																
1) PS / PH / RET=PH-PS	105,3	358,2	252,9		106,1	343,6	237,5		101,9	336,6	234,7		97,1	328,24	231,14	
2) PS / PH / RET=PH-PS	103,1	355,5	252,4		104,2	327,8	223,6		100,1	317,3	217,2		97,4	331,24	233,84	
3) PS / PH / RET=PH-PS	107	354,3	247,3		105,2	344,7	239,5		100,1	313,2	213,1		96,8	329,4	232,6	
4) PS / PH / RET=PH-PS	105,9	357	251,1		102,7	322,6	219,9		100,9	347,5	246,6		98,1	324,59	226,49	
Moyenne RET	250,925				230,125				227,9				231,0175			
ABSORPTION TOTALE (cc)																
1) Poids (g) / AT	103,5		1492		98,9		1424		99,7		1466		95,9		1372	
2) Poids (g) / AT	104,8		1486		101,3		1408		99,3		1406		96,3		1345	
3) Poids (g) / AT	106,2		1554		101,5		1404		97,2		1451		96,2		1402	
4) Poids (g) / AT	103,9		1527		102,6		1431		99,1		1427		97,7		1408	
Moyenne AT	1514,75				1416,75				1437,5				1381,75			
ABSORPTION 10" (cc)																
1) ABS10	584				619				540				632			
2) ABS10	558				615				555				592			
3) ABS10	583				624				561				633			
4) ABS10	546				625				530				614			
Moyenne ABS10	567,75				620,75				546,5				617,75			
DEFIBRATION																
1) %N / %ACC / %FIN	3,21	84,88	11,91		6,15	78,9	14,95		5,64	86,75	7,61		5,03	87,95	7,01	
2) %N / %ACC / %FIN	2,98	86,06	10,96		4,99	77,42	17,59		5,13	80,67	14,19		4,29	87,5	8,21	
3) %N / %ACC / %FIN	2,8	84,21	12,98		4,95	79,18	15,87		6,57	78,01	15,43		5,79	86,47	7,74	
4) %N / %ACC / %FIN	3,06	80,4	16,54		6,74	81,3	11,95		6,2	73,61	20,19		5,06	88,29	6,66	
Moyenne %ACC	83,8875				79,2				79,76				87,5525			

ESSAI	5				6				7				8			
TENUE MATELAS (cN)																
1) TM	415,6				183,6				353,6				241,1			
2) TM	414,2				164,8				498,8				361,6			
3) TM	366,2				260,1				427,1				260,9			
4) TM	265,8				190,1				459,1				357,6			
Moyenne TM	365,45				199,65				434,65				305,3			
TEMPS D'ACQUISITION (sec.)																
1) TA1 / TA2 / TA3 / TTA	20,24	38,02	49,83	108,09	22,12	41,97	47,5	111,59	16,59	36,18	41,75	94,52	23,82	52,85	58,84	135,51
2) TA1 / TA2 / TA3 / TTA	18,27	41,9	49,36	109,53	23,22	45,38	49,87	118,47	16,68	36,5	41,57	94,75	25,66	48,96	53,31	127,93
3) TA1 / TA2 / TA3 / TTA	19,21	38,64	45,64	103,49	25,18	46,79	51,28	123,25	17,37	36,16	45,81	99,34	22,97	48,72	53,94	125,63
4) TA1 / TA2 / TA3 / TTA	19,02	39,74	47,2	105,96	24,85	41,18	44,19	110,22	16,78	36,16	40,15	93,09	25,47	47,31	52,09	124,87
Moyenne TTA	106,7675				115,8825				95,425				128,485			
RETENTION (g)																
1) PS / PH / RET=PH-PS	103	332,92	229,92		99,4	346,43	247,03		100,9	352,63	251,73		103,82	323,59	219,77	
2) PS / PH / RET=PH-PS	102,8	335,65	232,85		98,3	320,95	222,65		104,6	344,03	239,43		104,27	352,27	248	
3) PS / PH / RET=PH-PS	98,9	314,63	215,73		98,3	329,72	231,42		102,4	360,4	258		105,22	310,73	205,51	
4) PS / PH / RET=PH-PS	99,7	306,15	206,45		99,5	343,7	244,2		102,5	355,3	252,8		104,25	329,25	225	
Moyenne RET	221,2375				236,325				250,49				224,57			
ABSORPTION TOTALE (cc)																
1) Poids (g) / AT	99,21		1389		95,84		1402		105,3		1537		104,52		1426	
2) Poids (g) / AT	99,51		1366		97,45		1380		103,3		1428		102,81		1420	
3) Poids (g) / AT	99,6		1410		96,45		1348		104,9		1454		102,24		1444	
4) Poids (g) / AT	101,4		1446		98,6		1399		104,1		1441		106,13		1580	
Moyenne AT	1402,75				1382,25				1465				1467,5			
ABSORPTION 10" (cc)																
1) ABS10	594				543				615				585			
2) ABS10	616				513				590				545			
3) ABS10	565				511				614				541			
4) ABS10	565				534				584				538			
Moyenne ABS10	585				525,25				600,75				552,25			
DEFIBRATION																
1) %N / %ACC / %FIN	6,36	81,54	12,1		7,17	84	8,83		3,79	87,78	8,43		5,94	85,11	8,95	
2) %N / %ACC / %FIN	7,49	84,5	8,01		6,9	84,01	9,08		4,25	83,49	12,26		5,98	84,65	9,37	
3) %N / %ACC / %FIN	6,74	84,16	9,1		7,68	86,48	5,84		3,72	82,8	13,48		6,44	84,11	9,45	
4) %N / %ACC / %FIN	6,51	83,95	9,55		7,57	86,2	6,23		3,19	79,02	17,79		6,42	78,22	15,36	
Moyenne %ACC	83,5375				85,1725				83,2725				83,0225			

ESSAI	9				10				11				12			
TENUE MATELAS (cN)																
1) TM	504,2				404,3				2009				234,9			
2) TM	662,3				284,6				3129				150,9			
3) TM	704,7				324				4106				277,8			
4) TM	528				356,2				3565				245,1			
Moyenne TM	599,8				342,275				3202,25				227,175			
TEMPS D'ACQUISITION (sec.)																
1) TA1 / TA2 / TA3 / TTA	18,31	40,75	45,91	104,97	26,58	49,33	70,02	145,93	23,56	45,85	56,03	125,44	23,69	44,31	51,16	119,16
2) TA1 / TA2 / TA3 / TTA	20,84	43,81	47,91	112,56	28,68	59,8	70,08	158,56	22,81	43,37	53	119,18	24,13	49,62	54,75	128,5
3) TA1 / TA2 / TA3 / TTA	19,35	44,22	49,1	112,67	27,02	55,3	66,55	148,87	19,57	41,5	48,19	109,26	23,65	44,35	51,79	119,79
4) TA1 / TA2 / TA3 / TTA	20,34	46,03	53,16	119,53	25,77	48,62	57,61	132	23,16	46,93	58,03	128,12	27,59	47,22	54,22	129,03
Moyenne TTA	112,4325				146,34				120,5				124,12			
RETENTION (g)																
1) PS / PH / RET=PH-PS	102,3	344,42	242,12		101,7	345,34	243,64		104,46	333,81	229,35		99,23	332,87	233,64	
2) PS / PH / RET=PH-PS	103,1	353,02	249,92		106,4	337,1	230,7		105,87	372,49	266,62		99,5	328,06	228,56	
3) PS / PH / RET=PH-PS	103,5	347,03	243,53		105,2	320,45	215,25		104,6	327,33	222,73		100,78	350,88	250,1	
4) PS / PH / RET=PH-PS	101,1	347,92	246,82		103,6	348,02	244,42		103,79	345,7	241,91		97,41	330,7	233,29	
Moyenne RET	245,5975				233,5025				240,1525				236,3975			
ABSORPTION TOTALE (cc)																
1) Poids (g) / AT	100,24		1423		103,78		1490		104,51		1281		96,95		1421	
2) Poids (g) / AT	99,6		1442		103,42		1448		101,55		1236		95,94		1428	
3) Poids (g) / AT	103,15		1471		103,44		1427		103,28		1287		95,96		1395	
4) Poids (g) / AT	100,42		1402		103,07		1430		99,74		1278		99,29		1410	
Moyenne AT	1434,5				1448,75				1270,5				1413,5			
ABSORPTION 10" (cc)																
1) ABS10	633				518				498				500			
2) ABS10	576				526				520				572			
3) ABS10	590				551				494				506			
4) ABS10	573				490				533				546			
Moyenne ABS10	593				521,25				511,25				531			
DEFIBRATION																
1) %N / %ACC / %FIN	5,39	86,41	8,2		3,98	85,5	10,52		4,31	82,4	13,3		6,94	86,19	6,88	
2) %N / %ACC / %FIN	5,84	89,71	4,44		3,18	87,71	9,11		4,26	86,74	8,99		7,97	81,41	10,61	
3) %N / %ACC / %FIN	5,32	87,33	7,35		3,19	88,87	7,94		4,74	84,28	10,98		6,68	84,96	8,36	
4) %N / %ACC / %FIN	5,93	85,83	8,23		2,84	88,55	8,61		4,16	82,06	13,78		6,96	85,22	7,82	
Moyenne %ACC	87,32				87,6575				83,87				84,445			

ESSAI	13				14				15				16			
TENUE MATELAS (cN)																
1) TM	599,7				259,3				426				6926			
2) TM	458,8				320				426,8				2744			
3) TM	934,5				386				322,1				7409			
4) TM	869,5				430,3				410,7				9866			
Moyenne TM	715,625				348,9				396,4				6736,25			
TEMPS D'ACQUISITION (sec.)																
1) TA1 / TA2 / TA3 / TTA	31,57	54,94	62,34	148,85	24,47	49,84	57,63	131,94	22,9	42,52	51,21	116,63	18,78	36,75	42,72	98,25
2) TA1 / TA2 / TA3 / TTA	30,19	56,91	62,85	149,95	24,09	49,44	57,87	131,4	23,74	46,87	55,87	126,48	19,72	38,75	44,91	103,38
3) TA1 / TA2 / TA3 / TTA	30,12	54,4	62,03	146,55	23,85	49,16	52,29	125,3	27,24	48,33	59,58	135,15	20,69	42,13	51,53	114,35
4) TA1 / TA2 / TA3 / TTA	29,37	58,03	64,25	151,65	23,65	46,35	50,87	120,87	27,52	48,66	53,49	129,67	17,06	35,34	43,69	96,09
Moyenne TTA	149,25				127,3775				126,9825				103,0175			
RETENTION (g)																
1) PS / PH / RET=PH-PS	100,61	307,65	207,04		97,5	346,1	248,6		104,8	366,2	261,4		118,8	360,3	241,5	
2) PS / PH / RET=PH-PS	104,15	338,7	234,55		100	361,9	261,9		104,6	388	283,4		120,6	401,5	280,9	
3) PS / PH / RET=PH-PS	101,97	323,95	221,98		99,4	364,1	264,7		105,7	368,8	263,1		122,6	420,7	298,1	
4) PS / PH / RET=PH-PS	104,03	366,85	262,82		100,6	344,7	244,1		104,9	405,5	300,6		127,5	401,7	274,2	
Moyenne RET	231,5975				254,825				277,125				273,675			
ABSORPTION TOTALE (cc)																
1) Poids (g) / AT	101,24		1371		95,9		1355		103,2		1454		123,8		1597	
2) Poids (g) / AT	100,94		1387		98,9		1446		102,4		1534		129,4		1617	
3) Poids (g) / AT	101,93		1430		97,2		1369		100,5		1487		118,8		1532	
4) Poids (g) / AT	102,12		1458		97,1		1352		100,8		1455		118,2		1412	
Moyenne AT	1411,5				1380,5				1482,5				1539,5			
ABSORPTION 10" (cc)																
1) ABS10	498				554				521				642			
2) ABS10	501				555				524				674			
3) ABS10	511				562				544				626			
4) ABS10	514				554				524				597			
Moyenne ABS10	506				556,25				528,25				634,75			
DEFIBRATION																
1) %N / %ACC / %FIN	6,85	84,94	8,2		6,53	85,19	8,28		7,76	83,82	8,42		5,43	85,28	9,29	
2) %N / %ACC / %FIN	6,34	84,74	8,91		6,27	85,96	7,76		7,16	83,77	9,07		5,88	87,57	6,55	
3) %N / %ACC / %FIN	8,1	80,2	11,7		6,3	85,78	7,92		10,13	79,32	10,55		4,65	85,04	10,31	
4) %N / %ACC / %FIN	7,33	83,56	9,11		6,6	81,08	12,31		6,51	82,67	10,81		5,38	86,58	8,04	
Moyenne %ACC	83,36				84,5025				82,395				86,1175			

ESSAI	17				18				19			
TENUE MATELAS (cN)												
1) TM	531,3				111,4				642,9			
2) TM	642,9				267,4				342			
3) TM	603,8				163,5				476			
4) TM	364,4				196,2				416,4			
Moyenne TM	535,6				184,625				469,325			
TEMPS D'ACQUISITION (sec.)												
1) TA1 / TA2 / TA3 / TTA	17,28	37,28	43,72	98,28	21,09	44	48,72	113,81	14,59	42,6	48,75	105,94
2) TA1 / TA2 / TA3 / TTA	17,75	37,28	43,15	98,18	22,28	39,06	43,75	105,09	13,69	41	46,35	101,04
3) TA1 / TA2 / TA3 / TTA	18,6	39,91	45,9	104,41	23,78	40,38	46,82	110,98	14,65	40,22	45,5	100,37
4) TA1 / TA2 / TA3 / TTA	17,03	37,43	43,82	98,28	19,75	36,75	41,25	97,75	15,84	40,81	48,19	104,84
Moyenne TTA	99,7875				106,9075				103,0475			
RETENTION (g)												
1) PS / PH / RET=PH-PS	105	359,3	254,3		104,4	382,4	278		98,7	368,6	269,9	
2) PS / PH / RET=PH-PS	105,6	372,4	266,8		103,9	363,5	259,6		104,6	394,8	290,2	
3) PS / PH / RET=PH-PS	104,4	393,4	289		101,9	381,5	279,6		98,2	374,2	276	
4) PS / PH / RET=PH-PS	103,8	352,1	248,3		102	354,5	252,5		101	385,7	284,7	
Moyenne RET	264,6				267,425				280,2			
ABSORPTION TOTALE (cc)												
1) Poids (g) / AT	100,8		1406		100,8		1438		100,8		1522	
2) Poids (g) / AT	100,8		1403		99,4		1444		101,7		1536	
3) Poids (g) / AT	101,2		1385		98,9		1487		101		1525	
4) Poids (g) / AT	101,3		1435		99,6		1438		104,7		1589	
Moyenne AT	1407,25				1451,75				1543			
ABSORPTION 10" (cc)												
1) ABS10	558				570				673			
2) ABS10	594				558				670			
3) ABS10	622				535				658			
4) ABS10	628				560				649			
Moyenne ABS10	600,5				555,75				662,5			
DEFIBRATION												
1) %N / %ACC / %FIN	5,99	81,1	12,91		5,04	89,61	5,35		2,89	79,34	17,76	
2) %N / %ACC / %FIN	6,06	84,94	9		5,3	86,82	7,88		2,98	83,4	13,62	
3) %N / %ACC / %FIN	5,92	83,59	10,49		4,92	88,1	6,99		2,75	84,43	12,81	
4) %N / %ACC / %FIN	5,16	83,28	11,5		4,91	88,18	6,91					
Moyenne %ACC	83,2275				88,1775				82,39			

ANNEXE 2

PRÉCISION DES ENTRAÎNEMENTS (BORLAND)

TM (16%) H=10,0		
	# Essai	Précision (%)
1re série		
	3	20,81
	12	23,99
	15	3,31
	Moyenne	16,04
2e série		
	4	18,36
	7	1,16
	17	7,34
	Moyenne	8,95
3e série		
	1	5,88
	10	9,76
	14	34,98
	Moyenne	16,87
MOYENNE:		13,95

TA (14%) H=3,0		
	# Essai	Précision (%)
1re série		
	1	33,33
	4	10,25
	10	33,12
	16	35,33
	Moyenne	28,01
2e série		
	2	8,23
	6	0,69
	9	1,907
	14	34,4
	Moyenne	11,31
3e série		
	3	4,84
	8	14,88
	12	4,79
	17	38,18
	Moyenne	15,67
MOYENNE:		18,33

AT (14%) H=3,0		
	# Essai	Précision (%)
1re série		
	1	29,22
	4	21,47
	10	7,71
	16	39,69
	Moyenne	24,52
2e série		
	2	7,64
	6	27,73
	9	1,3
	14	22,71
	Moyenne	14,85
3e série		
	3	0,615
	8	12,45
	12	6,74
	17	7,9
	Moyenne	6,93
MOYENNE:		15,43

ABS10 (14%) H=3,0		
	# Essai	Précision (%)
1re série		
	1	5,61
	4	6,17
	10	10,93
	16	50,82
	Moyenne	18,38
2e série		
	2	22,3
	6	28,37
	9	10,26
	14	20,35
	Moyenne	20,32
3e série		
	3	9,99
	8	3,45
	12	2,83
	17	32,15
	Moyenne	12,11
MOYENNE:		16,94

RET (21%) H=3,0		
	# Essai	Précision (%)
1re série		
	1	11,71
	4	23,23
	10	14,41
	16	51,3
	Moyenne	25,16
2e série		
	2	12,89
	6	13,79
	9	10,06
	14	5,157
	Moyenne	10,47
3e série		
	3	34,39
	8	35,84
	12	33,54
	17	19,47
	Moyenne	30,81
MOYENNE:		22,15

ACC (21%) H=3,0		
	# Essai	Précision (%)
1re série		
	1	0,7
	4	45,45
	10	43,67
	16	30,1
	Moyenne	29,98
2e série		
	2	66,1
	6	7,06
	9	36,95
	14	2,67
	Moyenne	28,20
3e série		
	3	48,75
	8	11,77
	12	1,04
	17	11,54
	Moyenne	18,275
MOYENNE:		25,48

Learning rate= 0,1
Momentum = 0,2

ANNEXE 3

PRÉCISION DES VALIDATIONS (CADSIM)

	Entraînement vs YYZ	TM (sec)	Précision (%)
1re série			
	vs 3	351,39	20,81
	vs 12	354,602	24,00
	vs 15	378,83	3,31
	Moyenne		16,04
2e série			
	vs 4	283,83	18,36
	vs 7	428,49	1,16
	vs 17	574,59	7,34
	Moyenne		8,96
3e série			
	vs 1	320,77	5,88
	vs 10	394,105	9,76
	vs 14	534,7	34,99
	Moyenne		16,88

	Entraînement vs ZIG	TA (sec)	Précision (%)
1re série			
	vs 1	115,25	33,33
	vs 4	107,36	10,25
	vs 10	128,51	33,13
	vs 16	122,03	35,33
	Moyenne		28,01
2e série			
	vs 2	109,18	8,24
	vs 6	116,25	0,68
	vs 9	111,4	1,92
	vs 14	108,86	34,41
	Moyenne		11,31
3e série			
	vs 3	114,06	4,84
	vs 8	120,48	14,87
	vs 12	126,7	4,79
	vs 17	120,35	38,18
	Moyenne		15,67

	Entraînement vs ZIG	AT (sec)	Précision (%)
1re série			
	vs 1	1435,13	29,22
	vs 4	1440,25	21,47
	vs 10	1427,75	7,71
	vs 16	1431,33	39,70
	Moyenne		24,52
2e série			
	vs 2	1437,56	7,64
	vs 6	1457,83	27,74
	vs 9	1430,95	1,30
	vs 14	1442,4	22,72
	Moyenne		14,85
3e série			
	vs 3	1435,82	0,62
	vs 8	1433,56	12,46
	vs 12	1431,89	6,75
	vs 17	1428,83	7,90
	Moyenne		6,93

	Entraînement vs ZIG	ABS10 (sec)	Précision (%)
1re série			
	vs 1	576,544	5,62
	vs 4	608,08	6,18
	vs 10	538,35	10,93
	vs 16	555,22	50,82
	Moyenne		18,39
2e série			
	vs 2	585,84	22,31
	vs 6	569,65	28,37
	vs 9	576,93	10,27
	vs 14	588,1	20,35
	Moyenne		20,32
3e série			
	vs 3	562,13	9,99
	vs 8	546,85	3,45
	vs 12	535,44	2,84
	vs 17	550,18	32,15
	Moyenne		12,11

	Entraînement vs ZAG	RET (sec)	Précision (%)
1re série			
	vs 1	248,74	3,91
	vs 4	251,77	37,13
	vs 10	239,86	11,38
	vs 16	248,59	44,88
	Moyenne		24,33
2e série			
	vs 2	237,73	13,61
	vs 6	244,46	24,05
	vs 9	251,53	10,62
	vs 14	251,78	5,45
	Moyenne		13,43
3e série			
	vs 3	248,18	36,29
	vs 8	245,71	37,82
	vs 12	256,18	35,40
	vs 17	253,11	20,56
	Moyenne		32,52

	Entraînement vs ZAG	ACC (sec)	Précision (%)
1re série			
	vs 1	84,39	5,59
	vs 4	84,44	34,58
	vs 10	84,91	30,52
	vs 16	84,19	21,41
	Moyenne		23,03
2e série			
	vs 2	84,78	62,00
	vs 6	84,57	6,69
	vs 9	84,2	34,67
	vs 14	84,52	0,20
	Moyenne		25,89
3e série			
	vs 3	84,147	48,74
	vs 8	84,08	11,76
	vs 12	84,34	1,11
	vs 17	84,24	11,56
	Moyenne		18,29

ANNEXE 4

CALCULS DES EFFETS LORS DE L'ANALYSE PAR PARETO

discal	tm	ta	ret	at	abs10	acc
0,025	418,80	123,31	250,83	1420,95	553,58	84,76
0,05	334,53	113,44	237,78	1435,56	574,64	83,73
DIFF	-84,26	-9,88	-13,05	14,61	21,06	-1,03
1/2 effet	42,13	4,94	6,53	7,31	10,53	0,51

profsa	tm	ta	ret	at	abs10	acc
40	412,70	117,00	248,27	1437,64	565,44	83,84
48	359,38	119,75	240,34	1418,87	562,78	84,65
DIFF	-53,32	2,75	-7,94	-18,78	-2,66	0,81
1/2 effet	26,66	1,38	3,97	9,39	1,33	0,41

pression	tm	ta	ret	at	abs10	acc
15	330,96	116,01	245,17	1432,22	565,31	83,80
25	419,08	120,27	243,61	1425,09	563,16	84,60
DIFF	88,12	4,26	-1,55	-7,13	-2,16	0,80
1/2 effet	44,06	2,13	0,78	3,57	1,08	0,40

nbpate	tm	ta	ret	at	abs10	acc
2	344,86	120,36	240,05	1428,81	569,91	84,71
3	418,06	116,79	247,70	1427,81	559,48	83,88
DIFF	73,20	-3,56	7,65	-1,00	-10,43	-0,83
1/2 effet	36,60	1,78	3,82	0,50	5,21	0,41


disbreak	tm	ta	ret	at	abs10	acc
0,015	360,83	117,62	243,30	1438,69	568,97	84,94
0,04	405,64	118,98	245,11	1419,91	560,23	83,70
DIFF	44,81	1,36	1,81	-18,78	-8,74	-1,24
1/2 effet	22,40	0,68	0,91	9,39	4,37	0,62




prodrate	tm	ta	ret	at	abs10	acc
100	429,82	121,97	235,34	1424,34	559,72	83,32
160	359,77	115,50	251,47	1431,39	567,63	84,99
DIFF	-70,06	-6,47	16,13	7,04	7,91	1,68
1/2 effet	35,03	3,24	8,06	3,52	3,96	0,84

disbross	tm	ta	ret	at	abs10	acc
0	467,88	109,22	245,75	1410,95	591,11	84,29
5	322,38	127,54	242,86	1445,56	537,12	84,21
DIFF	-145,49	18,32	-2,89	34,61	-53,99	-0,08
1/2 effet	72,75	9,16	1,44	17,31	27,00	0,04

ANNEXE 5


GRAPHES DES EFFETS PAR PARETO






ANNEXE 6

GRAPHES DE PARETO





ANNEXE 7 **TABLEAUX DES EFFETS CALCULÉS PAR RDN**

327,03 22,28%	423,61 27,11%	493,92 19,73%	547,264 14,97%				84,10%
DISBROSS	DISCAL	PRESSION	NBPATE	PRODRATE	PROFSA	DISBREAK	TM
0	0,025	25	3	100	40	0,181	603,93
		▲	▲			▲	▲
▼	▼			▼	▼		
5	0,05	15	2	175	48	0,105	247,63

123,233 42,40%	118,503 10,85%	106,564 27,40%					80,65%
DISBROSS	DISCAL	PRODRATE	PRESSION	NBPATE	PROFSA	DISBREAK	TA
0	0,05	175	15	3	48	0,105	98,13
	▲	▲		▲	▲		▲
▼			▼			▼	
5	0,025	100	25	2	40	0,181	141,71

239,513 19,87%	248,897 28,63%	256,07 21,88%	260,06 12,17%				82,55%
PRODRATE	PRESSION	NBPATE	DISCAL	PROFSA	DISBROSS	DISBREAK	RET
175	15	3	0,025	40	5	0,105	265,78
▲		▲					▲
	▼		▼	▼	▼	▼	
100	25	2	0,05	48	0	0,181	233

1428,5 38,85%	1433,81 25,09%	1436,58 13,09%					77,03%
DISBROSS	DISCAL	NBPATE	PROFSA	PRESSION	DISBREAK	PRODRATE	AT
5	0,05	3	40	15	0,105	175	1441,44
▲	▲	▲				▲	▲
			▼	▼	▼		
0	0,025	2	48	25	0,181	100	1420,28

522,64 5,81%	557,31 28,69%	611,08 44,49%					78,99%
DISBROSS	DISCAL	DISBREAK	NBPATE	PRODRATE	PROFSA	PRESSION	ABS10
0	0,05	0,105	3	175	48	15	636,47
	▲		▲	▲	▲		▲
▼		▼				▼	
5	0,025	0,181	2	100	40	25	515,62

84,012 23,16%	84,158 25,61%	84,288 22,81%	84,37 14,39%				85,96%
PRODRATE	PRESSION	DISCAL	NBPATE	DISBREAK	DISBROSS	PROFSA	%ACC
175	15	0,025	3	0,105	5	40	84,45
▲			▲		▲		▲
	▼	▼		▼		▼	
100	25	0,05	2	0,181	0	48	83,88